

**Vysoká škola báňská – Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství**

**Dynamické sledování a evaluace geometrických
vlastností cévního systému v závislosti na tlakovém namáhání**

**Dynamical Tracking and Evaluation of Blood Vessel
System Geometrical Features Depending on Pressure Strain**

2020

Bc. Tereza Muchová

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Tereza Muchová**

Studijní program: N2649 Elektrotechnika

Studijní obor: 3901T009 Biomedicínské inženýrství

Téma: **Dynamické sledování a evaluace geometrických vlastností cévního systému v závislosti na tlakovém namáhání**
Dynamical Tracking and Evaluation of Blood Vessel System
Geometrical Features Depending on Pressure Strain

Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování mechanických vlastností cévního systému.
2. Nastudování algoritmů pro extrakci parametrů, hodnotících geometrii objektů z obrazu.
3. Rešerše metod pro real-time sledování dynamických objektů z video záznamu.
4. Rešerše metod pro sledování geometrických vlastností objektů z video signálu.
5. Analýza dynamických záznamů tlakového namáhání umělého cévního systému.
6. Návrh plně automatického algoritmu pro real-time detekci geometrických parametrů z video signálu.
7. Modelování dynamiky cévního systému v průběhu tlakového namáhání.
8. Vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

- [1] BOVIK, Alan C., ed. *Handbook of image and video processing*. Second edition. Amsterdam: Elsevier, 2007. ISBN 978-0-12-119792-6.
- [2] MCANDREW, Alasdair. *Introduction to digital image processing with MATLAB*. Boston: Thomson Course Technology, c2004. ISBN 0-534-40011-6.
- [3] KONVIČKOVÁ, Svatava a Jaroslav VALENTA. *Biomechanika srdečně cévního systému člověka*. Vyd. 2. Praha: Česká technika - nakladatelství ČVUT, 2006. ISBN 80-01-03425-9.
- [4] NICHOLS, Wilmer W. *McDonald's blood flow in arteries: theoretical, experimental and clinical principles*. 6th ed. Boca Raton: CRC Press, c2011. ISBN 978-0-340-98501-4.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení studenta

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně. Uvedla jsem všechny literární prameny a publikace, ze kterých jsem čerpala.

V Ostravě dne: *14. dubna 2020*

.....*Šudlová*.....
podpis studenta

Poděkování

Ráda bych poděkovala svému vedoucímu diplomové práce, panu Ing. Janu Kubíčkovi, za odborné vedení, cenné rady a konzultace průběžných i konečných výsledků při vytváření této diplomové práce.

Abstrakt

Cílem této diplomové práce je návrh automatizovaných procedur pro detekci geometrických parametrů z video signálu a modelování dynamiky cévního systému v průběhu tlakového namáhání. V rámci analýzy jsou diskutovány dva variabilní přístupy pro detekci zájmových objektů z videa. Jedná se o algoritmus, který na základě barevných markerů detekuje tloušťku aorty a metodu, která umožňuje sledování distribuce tloušťky aorty v celé její délce, včetně dalších geometrických parametrů, které jsou realizovány v prostředí MATLAB. Následně jsou tyto metody porovnány s cílem vyhodnocení efektivity algoritmů. Dále je zhodnocena efektivita předzpracování obrazu v případě modelu distribuce tloušťky aorty. Kromě prezentování vývoje algoritmu jsou v této práci popsány mechanické vlastnosti cévního systému, principy sledování geometrických vlastností nebo algoritmy pro extrakci parametrů. Následně je provedena signálová analýza, která testuje signifikance variability signálu pro variabilní úseky aorty a statistická analýza, zahrnující deskriptivní statistiku, dvouvýběrové testování mediánu hodnot pomocí Wilcoxonova testu a vícevýběrové testování provedené Kruskal-Wallisovým testem.

Klíčová slova

Aorta; video; detekce; geometrické parametry; zpracování obrazu; Skeleton metoda; metoda detekce barvy; MATLAB

Abstract

The aim of this diploma thesis is the design of automated procedures for the detection of geometric parameters from a video signal and modeling the dynamics of the vascular system during compressive stress. Within the analysis, two variable approaches for the detection of objects of interest from video are discussed. It is an algorithm that detects aortic thickness based on color markers and a method that allows monitoring the distribution of aortic thickness along its entire length, including other geometric parameters that are implemented in MATLAB. Subsequently, these methods are compared in order to evaluate the efficiency of algorithms. Furthermore, the efficiency of image preprocessing in the case of the aortic thickness distribution model is evaluated. In addition to presenting the development of the algorithm, this work describes the mechanical properties of the vascular system, the principles of monitoring geometric properties or algorithms for parameter extraction. Subsequently, signal analysis is performed to test the significance of signal variability for aortic variable regions and statistical analysis, including descriptive statistics, two-sample testing of median values using the Wilcoxon test, and multi-sample testing performed by the Kruskal-Wallis test

Key words

Aorta; video; detection; geometric parameters; image processing; Skeleton method; color detection method; MATLAB

Obsah

Seznam použitých zkratk.....	- 11 -
Seznam ilustrací	- 12 -
Seznam tabulek	- 14 -
Úvod.....	- 15 -
1 Video signál	- 16 -
1.1 Video formáty	- 16 -
1.1.1 AVI (Audio Video Interleave).....	- 16 -
1.1.2 OGM (Ogg Vorbis)	- 16 -
1.1.3 MPEG (Moving Picture Experts Group).....	- 16 -
1.1.4 RAV, DV, DIF	- 17 -
1.2 Zpracování video signálu	- 17 -
1.2.1 Video indexování	- 17 -
1.2.2 Vzorkování	- 17 -
1.2.3 Kvantování	- 18 -
1.2.4 Kódování	- 19 -
1.2.5 Komprese.....	- 19 -
2 Mechanické vlastnosti cévního systému	- 20 -
2.1 Cévní systém obecně	- 20 -
2.2 Aorta.....	- 20 -
2.3 Srdce.....	- 21 -
2.4 Tepny.....	- 21 -
2.5 Vliv faktorů na naměřené hodnoty	- 22 -
2.5.1 Vliv předpětí.....	- 22 -
2.5.2 Lokalizace	- 22 -
2.5.3 Vliv orientace vzorku	- 23 -
2.5.4 Vliv věku	- 23 -
2.5.5 Vliv teploty a rychlosti zatěžování	- 23 -
2.5.6 Vliv aterosklerózy	- 24 -
3 Algoritmy pro extrakci parametrů, hodnotících geometrii objektů z obrazu	- 25 -

4	Rešerše metod pro sledování dynamických objektů	- 27 -
4.1	Proces sledování.....	- 27 -
4.1.1	Zobrazení tvaru.....	- 27 -
4.1.2	Zobrazení vzhledu	- 28 -
4.1.3	Metody extrakce příznaků	- 28 -
4.2	Detekce objektů.....	- 29 -
4.2.1	Bodové detektory	- 29 -
4.2.2	Frame diferencing.....	- 29 -
4.2.3	Background subtraction.....	- 30 -
4.2.4	Optical flow	- 31 -
4.3	Sledování objektů.....	- 32 -
4.3.1	Sledování bodů	- 32 -
4.3.2	Kernel tracking	- 33 -
4.3.3	Sledování siluety	- 33 -
5	Sledování geometrických vlastností.....	- 34 -
5.1	Detekce barevného spektra.....	- 34 -
5.2	Skeleton.....	- 35 -
6	Design algoritmyzačních procedur pro detekci a sledování.....	- 37 -
6.1	Support Package for USB Webcams.....	- 37 -
6.1.1	Webcamlist.....	- 37 -
6.1.2	Webcam.....	- 37 -
6.2	Měřicí řetězec	- 38 -
6.3	Charakteristika dat použitých k analýze.....	- 40 -
6.4	Předzpracování obrazu	- 42 -
6.4.1	Podvzorkování obrazu	- 42 -
6.4.2	Mediánová filtrace.....	- 43 -
6.5	Model distribuce tloušťky aorty	- 44 -
6.5.1	Princip metody skeleton	- 44 -
6.5.2	Implementace algoritmu v prostředí MATLAB.....	- 46 -
6.5.3	Testování algoritmu na reálných datech.....	- 47 -
6.6	Návrh a realizace algoritmu na základě detekce jasového spektra markeru.....	- 48 -

6.6.1	Testování odstínu modré barvy a velikosti markeru	49 -
6.6.2	Funkčnost algoritmu	50 -
6.7	Srovnání metod	51 -
7	Modelování dynamiky cévního systému – analýza dat	52 -
7.1	Plocha a obvod aorty	52 -
7.2	Distribuce tloušťky aorty	53 -
8	Signálová analýza	58 -
8.1.1	Vliv lokalizace na naměřené parametry	60 -
8.1.2	Analýza frekvence	62 -
9	Statistická analýza	66 -
9.1	Použité parametry a testy	66 -
9.2	Statistická analýza pro parametr plochy	68 -
9.2.1	Výpočet deskriptivních parametrů	68 -
9.2.2	Dvouvýběrová charakteristika	68 -
9.2.3	Vícevýběrová charakteristika pro parametr plochy	72 -
9.3	Statistická analýza pro parametr obvodu	74 -
9.3.1	Výpočet deskriptivních parametrů	74 -
9.3.2	Dvouvýběrová charakteristika	74 -
9.3.3	Vícevýběrová charakteristika pro parameter obvodu	78 -
9.4	Statistická analýza pro parametr tloušťky	80 -
9.4.1	Výpočet deskriptivních parametrů	80 -
9.4.2	Dvouvýběrová charakteristika	81 -
9.4.3	Vícevýběrová charakteristika pro parameter tloušťky	85 -
9.5	Zhodnocení	87 -
	Závěr	88 -
	Použitá literatura	89 -
	Seznam příloh	I

Seznam použitých zkratk

1D	Jednorozměrný
2D	Dvourozměrný
3D	Trojrozměrný
AVI	Audio Video Interleave (formát multimediálního kontejneru)
CD	Compact Disc (kompaktní disk)
CFD	Computational Fluid Dynamics (výpočetní dynamika tekutin)
CO₂	Oxid uhličitý
DIF	Data Interchange Format (datový soubor kompatibilní s aplikací Excel)
DSS	Digitální satelitní systém
DV	Digital Video (digitální formát záznamu videa)
DVD	Digital Versatile Disc (digitální optický datový nosič)
GB	Gigabyte (označení jednotky množství informace používané v informatice)
HDTV	High-definition television (televize s vysokým rozlišením)
HSV	Hue, Saturation, Value (barevný model)
HVS	Human Visual System (spektrální citlivost tyčinek a čípků)
MPEG	Moving Picture Experts Group (skupina zařízení pro pohyblivý obraz)
OGM	Ogg Vorbis Media (formát určený k uložení zvuku nebo videa)
RGB	Red-green-blue (barevný model, aditivní způsob míchání barev)
ROI	Region of interest (oblast zájmu)
YCbCr	Barevný model s modrou a červenou chrominační komponentou
YUV	Barevný model používaný v televizním vysílání

Seznam ilustrací

Obr. 1: Blokové schéma procesu získání digitálního videa.....	16 -
Obr. 2: Příklad vzorkování analogového signálu	18 -
Obr. 3: Proces kvantování obrazu	18 -
Obr. 4: Ukázka kvantování obrazu	19 -
Obr. 5: Popis aorty, upraveno podle	21 -
Obr. 6: Závislost napětí – deformace aorty pro podélný (a) a obvodový (b) směr.....	23 -
Obr. 7: Vlevo zdravá céva, vpravo postižená céva aterosklerózou	24 -
Obr. 8: Ukázka gradientu	26 -
Obr. 9: Reprezentace objektů	28 -
Obr. 10: Vlevo aorta na snímku z MR, vpravo detekce hran aorty	28 -
Obr. 11: Původní video.	30 -
Obr. 12: Two frame diferencing	30 -
Obr. 13: Three frame diferencing	30 -
Obr. 14: Výsledky navrhované metody bez binarizace.....	31 -
Obr. 15: Rámec algoritmu.	32 -
Obr. 16: Vlevo optical flow detektor, vpravo navrhovaný detektor.....	32 -
Obr. 17: Blokové schéma algoritmu.....	34 -
Obr. 18: Sledování pohybu bílého míčku.....	35 -
Obr. 19: Vlevo 3D model cévy, vpravo středová čára.	35 -
Obr. 20: Algoritmus extrakce středové linie	36 -
Obr. 21: Měřicí řetězec modelu pro měření distribuce tloušťky.	38 -
Obr. 22: Model aorty zapojený v měřícím řetězci.....	39 -
Obr. 23: Měřicí řetězec s pulzačním čerpadlem a rezervoárem	39 -
Obr. 24: Frame 10 z videa1.	40 -
Obr. 25: Frame 10 z videa2.	41 -
Obr. 26: Frame 10 z videa3.	41 -
Obr. 27: Frame 10 z videa4.	41 -
Obr. 28: Frame 10 z videa5.	41 -
Obr. 29: Frame 10 z videa6.	41 -
Obr. 30: Frame 10 z videa7.	42 -
Obr. 31: Blokové schéma kroků předzpracování obrazu.	42 -
Obr. 32: Původní binární snímek (nahore), snímek po aplikaci „medfilt2“ (dole). ...	44 -
Obr. 33: Princip vzdálenostní transformace.	45 -
Obr. 34: Euklidovská vzdálenost.....	45 -
Obr. 35: Barevné mapování.....	46 -
Obr. 36: Vývojový diagram kroků algoritmu.....	46 -
Obr. 37: Testování na nativních snímcích.....	47 -
Obr. 38: Testování na předzpracovaných snímcích.....	48 -
Obr. 39: Blokové schéma algoritmu pro detekci daného objektu.	49 -

Obr. 40: Ověření správné detekce barvy testovaného algoritmu.....	49 -
Obr. 41: Chybný odstín modré barvy.	49 -
Obr. 42: Správná detekce modré barvy pro tmavě modrý i světle modrý marker.....	50 -
Obr. 43: Chybná detekce v závislosti na velikosti modrých markerů.	50 -
Obr. 44: Závislost tloušťky aorty na čase pro testovací video.	51 -
Obr. 45: Závislost plochy aorty v průběhu tlakového namáhání.....	52 -
Obr. 46: Závislost obvodu aorty na tlakovém namáhání.....	53 -
Obr. 47: Artefakt RBM.	53 -
Obr. 48: Chybná detekce kostry aorty na okraji snímku.	54 -
Obr. 49: Vyznačené body pro měření tloušťky na aortě.	54 -
Obr. 50: Závislost tloušťky aorty na čase v bodě 117.....	55 -
Obr. 51: Závislost tloušťky aorty na čase v bodě 169.....	55 -
Obr. 52: Závislost tloušťky aorty na čase v bodě 223.....	56 -
Obr. 53: Histogram rozložení poloměru všech tlouštěk aorty pro 252 framů.....	56 -
Obr. 54: Histogram rozložení poloměru všech tlouštěk aorty pro 252 framů.....	57 -
Obr. 55: Histogram rozložení poloměru tloušťky aorty pro 252 framů.....	57 -
Obr. 56: Filtrace signálu Savitzky-Golay filtrem.	63 -
Obr. 57: Detektor maxim aplikovaný na filtrovaný signál.	63 -
Obr. 58: Závislost vzdálenosti peak-peak na čase.....	64 -
Obr. 59: Krabicový graf, upraveno podle.....	67 -
Obr. 60: Krabicový graf pro videa 1, 2 a 3.....	69 -
Obr. 61: Krabicový graf pro videa 4,5,6 a 7.....	69 -
Obr. 62: QQ graf hodnot pro video 1, 2 a 4.	70 -
Obr. 63: Q-Q graf hodnot pro video 4, 5, 6 a 7.	70 -
Obr. 64: Krabicový graf pro videa 1 a 3.....	75 -
Obr. 65: Krabicový graf pro videa 2 a 4.....	75 -
Obr. 66: Krabicový graf pro videa 5, 6 a 7.....	76 -
Obr. 67: QQ graf hodnot pro videa 1, 2 a 3.....	76 -
Obr. 68: QQ graf hodnot pro videa 4, 5, 6 a 7.....	77 -
Obr. 69: Krabicový graf pro videa 1, 2, 3, 4, 6 a 7.....	82 -
Obr. 70: Krabicový graf pro video 5.	82 -
Obr. 71: QQ graf hodnot pro videa 1, 2 a 3.....	83 -
Obr. 72: QQ graf hodnot pro videa 4, 5, 6 a 7.....	83 -

Seznam tabulek

Tab. 1: Procentuální zastoupení kolagenu, elastinu a hladkého svalstva	22 -
Tab.2: Maximální procentuální prodloužení v podélném směru.....	22 -
Tab. 3: Tahové mechanické vlastnosti koronární tepny.	23 -
Tab. 4: Vybrané parametry pro hodnocení geometrie objektů.....	25 -
Tab. 5: Přehled použitých dat.....	40 -
Tab 6: Vliv podvzorkování na časovou náročnost.	43 -
Tab. 7: Nastavení masky mediánového filtru.....	43 -
Tab. 8: Vypočítané parametry plochy pro všechna videa.	58 -
Tab. 9: Vypočítané parametry obvodu pro všechna videa.	59 -
Tab. 10: Vypočítané parametry tloušťky v bodě 117 pro všechna videa.	59 -
Tab. 11: Vypočítané parametry tloušťky v bodě 169 pro všechna videa.	59 -
Tab. 12: Vypočítané parametry tloušťky v bodě 223 pro všechna videa	60 -
Tab. 13: Rozdíly středních hodnot mezi jednotlivými záznamy pro plochu v %.....	60 -
Tab. 14: Rozdíly středních hodnot mezi jednotlivými záznamy pro obvod v %.	61 -
Tab. 15: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku	61 -
Tab. 16: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku	61 -
Tab. 17: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku	62 -
Tab. 18: Maximální a minimální rozdíl mezi videi pro jednotlivé parametry.....	62 -
Tab. 19: Výpočet jednotlivých parametrů pro plochu pro každý záznam.....	64 -
Tab. 20: Výpočet jednotlivých parametrů pro obvod pro každý záznam.....	65 -
Tab. 21: Deskriptivní statistické údaje pro parametr plochy.....	68 -
Tab. 22: Ověření normality (Kolmogorův-Smirnov test).....	70 -
Tab. 23: Dvouvýběrové charakteristiky pro všechny kombinace videí.	71 -
Tab. 24: Kruskal-Wallisův test pro parametr plochy.	72 -
Tab. 25: Post-hoc Dunn analýza.....	73 -
Tab. 26: Deskriptivní statistické údaje pro parametr obvodu.....	74 -
Tab. 27: Ověření normality (Kolmogorův-Smirnov test).....	77 -
Tab. 28: Dvouvýběrové charakteristiky pro všechny kombinace videí.	78 -
Tab. 29: Kruskal-Wallisův test pro parametr obvodu.	79 -
Tab. 30: Post-hoc Dunn analýza.....	79 -
Tab. 31: Deskriptivní statistické údaje pro parametr tloušťky v bodě 117.	80 -
Tab. 32: Deskriptivní statistické údaje pro parametr tloušťky v bodě 169.	81 -
Tab. 33: Deskriptivní statistické údaje pro parametr tloušťky v bodě 223.	81 -
Tab. 34: Ověření normality (Kolmogorův-Smirnov test).....	84 -
Tab. 35: Dvouvýběrové charakteristiky pro všechny kombinace videí.	84 -
Tab. 36: Kruskal-Wallisův test pro parametr tloušťky.....	86 -
Tab. 37: Post-hoc Dunn analýza.....	86 -

Úvod

Lidské tělo je složeno převážně z tkání, které mají viskoelastický charakter. To znamená, že kombinuje elastické a viskózní vlastnosti. Jedná se o měkké biologické struktury, jako jsou stěny cév. Změny mechanických vlastností cévního systému nejsou pouze vlivem stárnutí organismu, ale také doprovodným jevem celé řady onemocnění. Odlišné mechanické chování lze předpokládat u zdravých tkání a u tkání poškozených patologickým procesem nebo modifikované stárnutím. Tyto poznatky mohou mít praktické využití při medicínské diagnostice, kde by modifikace mechanické vlastnosti tkáně sloužila jako marker patologického procesu. V dnešní době v klinické medicíně roste zájem o sledování změn periferního odporu cév a zejména cévní roztažnosti jako parametru hodnotící stav kardiovaskulární soustavy.

Kardiovaskulární onemocnění jsou jednou z nejčastějších příčin úmrtí ve vyspělých zemích a řadí se mezi civilizační onemocnění. Mezi nejčastější problémy spojené s kardiovaskulárním systémem patří zúžení nebo ucpání cév a s tím související ischemie z důvodu aterosklerózy. V životně důležitých orgánech je tato neprůchodnost cévy velmi nebezpečná. Dalším problémem jsou aneurysmata neboli výdutě, které jsou náchylné k protržení. To má za následek masivní krvácení. Také vysoká hodnota systolického krevního tlaku je důležitým rizikovým faktorem pro zvýšenou tuhost cévní stěny. Vysoký krevní tlak urychluje proces aterosklerózy, což vede k mrtvici, infarktu myokardu, selhání ledvin a dalším onemocněním.

Cílem této práce je analýza a geneze algoritmů pro detekci morfologické struktury stěny aorty a konsekventní výpočet dynamických parametrů, které reprezentují pohyb aortální stěny v důsledku mechanického namáhání. Obsahem není pouze samotné prezentování navrženého algoritmu, ale také přiblížení oblastí potřebných k pochopení dané problematiky. Jelikož je tato práce založena na detekci geometrických parametrů z video signálu, v první kapitole je vypracována teorie zpracování video signálu. Druhá kapitola se věnuje mechanickým vlastnostem cévního systému. Ve třetí kapitole jsou popsány algoritmy pro extrakci parametrů, hodnotících geometrii objektů z obrazu. Rešeršní část je uvedena v kapitole čtyři a pět, která pojednává o metodách pro sledování dynamických objektů a sledování geometrických vlastností objektů z video záznamu.

Samotná praktická část je uvedena v kapitole šest, která se zabývá návrhem algoritmu pro detekci geometrických parametrů. Kapitola se věnuje popisu měřicího řetězce, datům použitých k analýze, předzpracování obrazu, popisu a realizaci modelu distribuce tloušťky a metody detekce barevného spektra s následným testováním na reálných datech. Dále je popsáno modelování dynamiky, které je uskutečněno pomocí tří parametrů – plochy, obvodu a tloušťky aorty. V další kapitole je popsána signálová analýza, kde je zkoumán vliv lokalizace na naměřené parametry a analýza frekvence. V poslední deváté kapitole je uvedena statistická analýza, pomocí které bude doloženo, zda místo měření je statisticky významné pro měření míry deformace.

1 Video signál

Video signál je sekvence po sobě jdoucích obrazů, které zobrazují situaci v jednotlivých časových okamžicích. Skutečný pohyb ale probíhá plynule. Pokud chceme zachytit pohyb, nejsnazší cesta je vyfotografování pohybu pomocí několika snímků rychle za sebou. Pokud ale promítáme snímky ve stejném tempu, v jakém byly pořízeny, máme zachycený trhaný pohyb. Později bylo zjištěno, že mozek od sebe nedokáže rozlišit více než 15–20 snímků za sekundu. To znamená, že stačí zaznamenat snímky s touto frekvencí a poté ji touto frekvencí i promítat. Lidské oko bude tento sled snímků vnímat jako plynulý pohyb. Dnes se ve filmu používá frekvence 25 nebo 30 snímků za sekundu. Blokové schéma znázorňující proces získání video signálu je na Obr. 1.



Obr. 1: Blokové schéma procesu získání digitálního videa.

Časové vzorkování – video se skládá z posloupnosti obrazů, zobrazených v rychlém sledu tak, aby bylo možné vytvořit iluze nepřetržitého pohybu. Pokud je mezera mezi po sobě jdoucími snímky příliš velká, je pozorován trhavý pohyb. Citlivost lidského vizuálního systému HVS výrazně klesá při vysokých frekvencích snímků. Většina video formátů používá časové vzorkovací frekvence 24 snímků za sekundu a vyšší.

Prostorové vzorkování – citlivost HVS se mění podle prostorové frekvence obrázku. V praxi se na vzorek jasu použije 8 bitů.

1.1 Video formáty

Tato podkapitola je věnována typům formátů digitálního videa. Jedná se o typ formátu souboru pro ukládání digitálních dat v počítačovém systému. Pro zpracování videa existuje velké množství formátů, které se liší zejména ve velikosti, kompresi i kvalitě.

1.1.1 AVI (Audio Video Interleave)

Jedná se o nejpoužívanější formát pro zápis obrazu a zvuku do souboru používaný především ve Windows. Velkou výhodou tohoto formátu je jeho podpora v různých druzích přehrávačů a podpora velkého množství kodeků videa zvuku. Na všechny snímky je použit stejný stupeň komprese [2].

1.1.2 OGM (Ogg Vorbis)

Je formát určený k uložení zvuku nebo videa. Mezi výhody patří možnost použití více video stop, audio stop a titulkových stop v jednom souboru. Nevýhodou tohoto typu formátu je, že po uložení nahrávky už ji nelze nijak upravit, a proto se používá nejčastěji pro uložení konečné verze [2].

1.1.3 MPEG (Moving Picture Experts Group)

Formát pro zápis a kompresi videa z obrazové informace zachovává pouze každý X-tý snímek. Výhodou je, že lze dosáhnout velkého zmenšení objemu dat bez vizuálně rozpoznatelné degradace

kvality videa. Tento typ formátu je využíván zejména pro data určená pouze k přehrávání (např. DVD, Video CD, atd.) [2].

1.1.4 RAV, DV, DIF

Jsou ekvivalentem formátu AVI vyvinuté jednotlivými výrobci hardwaru pro ukládání dat. Nevýhodou těchto formátů je, že s těmito soubory může pracovat pouze program dodaný k různým video editačním kartám. Při použití tohoto typu souboru v některé z rozšířenějších aplikací je nutno tento formát převést na AVI [2].

1.2 Zpracování video signálu

Reálný obraz lze charakterizovat spojitou funkcí, např. jas. Obraz, který je snímán kamerou, má nekonečný rozsah obrazových hodnot, který však bude zobrazen konečným množstvím pixelů. Přechod od spojitě funkce obrazu k diskrétní funkci se nazývá digitalizace obrazu. Digitalizace obrazu probíhá ve dvou krocích, a to vzorkování a kvantování [3].

Technologie zpracování videa způsobila revoluci ve světě multimédií s produkty jako například Digital Versatile Disk (DVD), digitální satelitní systém (DSS), televize s vysokým rozlišením (HDTV), digitální fotoaparáty a videokamery.

1.2.1 Video indexování

Video indexování je nezbytné pro usnadnění efektivního vyhledávání a prohlížení obsahu vizuální informace uložené ve velkých multimediálních databázích.

1.2.2 Vzorkování


Jedná se o zaznamenávání hodnot (vzorků) v předem zvolených časových intervalech. Příklad vzorkování analogového signálu je uveden na Obr. 2. Vzdálenost mezi jednotlivými vzorky se nazývá vzorkovací perioda T_{vz} . Vzorkovací frekvence f_{vz} se pak dá vyjádřit takto:

$$f_{vz} = \frac{1}{T_{vz}} \quad (1.1)$$

Čím je f_{vz} větší, tím kvalitnější je obraz. Minimální velikost f_{vz} je dána Shannonovým vzorkovacím teorémem, který říká: „*Přesná rekonstrukce spojitěho, frekvenčně omezeného signálu z jeho vzorků je možná tehdy, pokud byla vzorkovací frekvence vyšší než dvojnásobek nejvyšší harmonické složky vzorkovaného signálu.*“. Tedy:

$$f_{vz} > 2f_{max} \quad (1.2)$$

Při špatně zvolené velikosti f_{vz} hovoříme o tzv. aliasingu. Tedy o chybě vzorkování, která vystihuje jev, ke kterému dojde právě při nedodržení Shannonova teorému. Aby k této chybě nedošlo, je velmi často využit antialiasingový filtr, který je tvořen dolní propustí. U digitálních fotoaparátů a TV techniky se nejčastěji jako antialiasingový filtr využívá zmatněné sklo umístěné před CCD snímač, který způsobuje mírné rozostření detailů obrazu a tím zabraňuje vzniku aliasingu [3],[4].




Obr. 2: Příklad vzorkování analogového signálu [4].

1.2.3 Kvantování

Při praktické reprezentaci signálu je potřeba jednotlivé vzorky signálu uchovávat v proměnných s omezeným rozsahem. Proto je proveden převod skutečných úrovní signálu na hodnoty, které lze uchovávat v proměnných libovolného typu. Tento proces se nazývá kvantování.

Kvantování probíhá v oboru hodnot obrazové funkce, který se rozdělí na intervaly a je jim přidělena zástupní hodnota. Touto hodnotou bývá nejčastěji průměr celého intervalu. Na Obr. 3 je zobrazen proces kvantování obrazu [3].




Obr. 3: Proces kvantování obrazu [3].

Černé vodorovné přímky udávají kvantovací úrovně. Původní amplitudě signálu se přiřadí nejbližší kvantovací úroveň. Výšky impulsů (červeně) se dále nepřenesají přesně, ale vždy jen s celou úrovní. Tím je do signálu zanesena chyba, která má vlastnosti šumu a nazývá se proto kvantizační šum.

Při kvantování dochází ke ztrátě informace. Množina hodnot je nahrazena jedinou hodnotou. Tato ztráta se označuje jako kvantizační chyba a v počítačové grafice se projevuje například na plochách s malou změnou gradientu jako náhlý skok barev. Původně hladký barevný přechod je nahrazen skokovou změnou. Tento jev je znázorněn na Obr. 4. Faktor, který tuto chybu zesiluje, je lidské vnímání.

Oko je citlivé na výskyt hran a vnímá tento přechod jako novou informaci v obraze. Změny gradientu ovlivňují vnímání přilehlých ploch s konstantním jasem. Tento jev byl poprvé popsán na konci 18. st. fyzikem Ernestem Machem, proto je nazýván Machovy proužky [3].



Obr. 4: Ukázka kvantování obrazu [4].

1.2.4 Kódování

Kódování je proces konverze obrazových dat z jednoho formátu do druhého, který je potřeba pro přenos, ukládání či kompresi nebo dekompresi signálu.

1.2.5 Komprese

Vzhledem k tomu, že v jedné sekundě videozáznamu je 25–30 snímků, běžný film by zabral 200 GB. Disky s takovou kapacitou už existují, ale zásadním problémem by byl datový tok (množství dat, které musí proběhnout systémem za jednotku času). Čím vyšší kvalita je požadována, tím je nutný větší datový tok. Řešením je komprese neboli snížení velikosti videa. Pomocí komprese lze snížit velikost souborů na zlomek původní hodnoty, ovšem za cenu ztráty kvality. Do určité míry není tato ztráta kvality rozpoznatelná.

Komprese hledá místa se stejnými nebo podobnými barvami. Pokud jsou nalezena, pak na tyto body nebude nahlížet jako na samostatné body, ale na skupinu bodů, které mají stejnou barvu.

Nedá se jednoznačně určit, jak stanovit vhodnou míru komprese. Obecně je nejlepší použít střední hodnoty. Jen nejvýkonnější počítače umožní tzv. real-time kompresi (v reálném čase) [5].

2 Mechanické vlastnosti cévního systému

Měkké tkáně mají tyto viskoelastické vlastnosti:

1. Nelineární závislost napětí–deformace.
2. Při konstantní deformaci se u nich projevuje relaxace, při konstantním tahu se projevuje creep (tečení materiálu) a při cyklickém namáhání hystereze.
3. Vykazují závislost na historii zatížení.
4. Cévy jsou v organismu předepjaty, takže např. při experimentech je obtížné určit počáteční stav.
5. Biologické tkáně se při zahřátí smršťují. Pokud jsou podrobeny deformaci, zvyšují teplotu, při relaxaci jejich teplota klesá. Těmito vlastnostmi připomínají měkké tkáně pryž, ze které vychází řada modelů.

Z výše uvedených poznatků vyplývá, že výzkum v této oblasti je složitý. Na pacientovi lze jen výjimečně provádět určité experimenty, některé údaje nelze zjišťovat vůbec. Proto je většina experimentů prováděna na zvířatech [6].


2.1 Cévní systém obecně

Cévní systém je složen ze srdce, krevních a mízních cév, kostní dřeně, sleziny, mízních uzlin a příslušného nervového řízení. Nejdůležitějším orgánem krevního oběhu je srdce. Skládá se z pravé a levé komory a slouží jako svalová pumpa. Žilní krev z celého organismu vstupuje žilami do pravé síně a dále do levé komory. Z pravé komory putuje krev do plicnice, která rozvádí krev do plic. V plicích se větve plicních tepen dělí až na vlásečnice, což jsou nejmenší cévy. Probíhá tam výměna plynů mezi alveolárním vzduchem a krví, dochází k okysličení krve a snížení obsahu CO_2 . Okysličená krev se vrací čtyřmi plicními žilami do levé síně srdce. Odtud putuje krev do levé komory a z ní do aorty, největšího tepenného kmene. Aorta rozvádí krev po celém těle. Krev se po odevzdání kyslíku tkáním stává venosní krví. Kapiláry se spojí mezi sebou a vytvoří žíly. Všechny žíly se sbíhají ve dva velké žilní kmeny, a to horní a dolní dutou žílu. Horní dutá žíla sbírá krev z oblasti orgánů hlavy a krku a horních končetin. Dolní dutá žíla naopak z dolních končetin a ze stěn orgánů pánve a břicha. Obě žíly přivádějí krev do pravé síně. Tento celý oběh se nazývá celkový krevní oběh [6].

2.2 Aorta

Aorta je nejsilnější a nejdelší tepnou v lidském těle. Vystupuje z levé srdeční komory a rozvádí krev do celého těla. Nákres aorty včetně jejích úseků lze vidět na Obr. 5. Aorta se dělí se na tři hlavní úseky.

1. Vzestupná srdečnice (aorta ascendens) – poměrně krátký úsek. Vystupuje z ní pravá a levá věnčitá (koronární) tepna, která má za úkol vyživovat srdce.
2. Oblouk srdečnice (arcus aortae) – z oblouku odstupují tři tepenné kmeny – kmen hlavově pažní, levá společná krkavice a levá podklíčková tepna.
3. Sestupná srdečnice (aorta descendens) – navazuje na aortální oblouk a sestupuje dutinou hrudní a břišní do výše 4. bederního obratle. Tam se dělí na 2 společné tepny kyčelní, které vyživují dolní končetiny [6].



Obr. 5: Popis aorty, upraveno podle [15].

2.3 Srdce

Srdce je jedním z nejdůležitějších orgánů v lidském těle. Jedná se o dutý svalový orgán, který se periodicky stahuje a tím zajišťuje průtok krve cévním systémem. Příčně pruhovaná srdeční svalovina, zasahující i do stěn velkých cév, je nejobjemnější složkou stěny srdce. Existuje mnoho faktorů, např. vliv věku, okolního prostředí, typ fyzické námahy a další, které působí na správnou funkci srdce [6].

2.4 Tepny

Tepny, do kterých srdce pumpuje krev, jsou součástí cévního systému. Stěna tepen se skládá ze tří vrstev:

1. tunica intima (interna)
2. tunica media
3. tunica adventitia (externa)

Vnitřní struktura jednotlivých vrstev se v závislosti na druhu cévy může značně lišit. Vnitřní vrstva (tunica intima) se skládá z endotelových buněk, kterými jsou vystlány všechny cévy.

Pod vnitřní vrstvou se nachází subendotelová vazivová vrstva a elastická membrána, tvořena kolagenními a elastickými vlákny. Střední vrstva (tunica media) je silná svalová vrstva, ve které se nachází 40 až 60 elastických membrán. Mezi nimi procházejí pod úhlem 30° až 50° k podélné ose cévy vlákna hladkých svalů. Toto uspořádání je zásadní pro periodický způsob namáhání stěny cév a umožňuje tak její zpětné smrštění po průchodu pulsní vlny. Na hranici střední a vnější vrstvy (tunica adventitia) je membrána, složená z podélně orientovaných silných elastických vláken a svazků kolagenních fibril. Vnější vrstva se skládá z kolagenních vláken.

Elastin vykazuje elastické vlastnosti, kolagen je zodpovědný za pružnost a pevnost. Vlákná elastinu a kolagenu se zapojují ve fyziologickém stavu. Kolagenní vlákna se projevují u velkých deformací. Elastinová a kolagenní vlákna jsou významná pouze u pasivních vlastností cévní stěny. Komplexní chování cévní stěny dotváří hladká svalovina a vnitřní pnutí. Aktivita hladkého svalstva může být vyvolána nervovou soustavou. Obsah elastinu, kolagenu a hladkého svalstva v cévní stěně bude ovlivňovat mechanické chování cévy. V Tab. 1 je uvedeno procentuální zastoupení kolagenu, elastinu a hladkého svalstva ve vzestupné části aorty a plicnice psa [6].

Tab. 1: Procentuální zastoupení kolagenu, elastinu a hladkého svalstva ve vzestupné části aorty a plicnice psa.

	Kolagen (%)	Elastin (%)	Hladký sval (%)
Vzestupná část aorty	15,2–17,2	46,8–48,6	35
Kmen plicnice	9,1	21,0	65
Pravá plicnice	9,1	17,4	65
Levá plicnice	7,6	17,4	68

Tepny se podle složení a rozsahu jednotlivých vrstev dělí na 3 základní typy:

1. tepénky
2. tepny malého a středního průměru
3. tepny velkého průměru

2.5 Vliv faktorů na naměřené hodnoty

V této podkapitole jsou uvedeny vlivy faktorů na naměřené hodnoty.

2.5.1 Vliv předpětí

Tepny v lidském těle jsou za fyziologického stavu předepnuty. Přesná velikost předpětí je velmi těžko změřitelná. Aorta pracuje kolem počátečního stavu napjatosti, za kterého je deformace stěny asi 70 %. Při experimentech na zvířatech bylo zjištěno, že stupeň zkrácení a smrštění vzorků cév po vyjmutí z organismu závisí na věku [6].

2.5.2 Lokalizace


Se vzdáleností od srdce se u tepen mohou měnit funkční podmínky. Na lokalizaci vzorku závisí řada mechanických vlastností. V Tab.2 jsou uvedeny hodnoty maximálního procentuálního prodloužení v podélném směru [14].

Tab.2: Maximální procentuální prodloužení v podélném směru u jednotlivých částí.

Břišní aorta (aorta abdominalis)	148 %
Hrudní aorta (aorta thoracica)	145 %
Stehenní aorta (aorta femoralis)	124 %
Společná krční tepna (arteria carotis communis)	124 %

2.5.3 Vliv orientace vzorku

Podobně jako u vlivu lokalizace má vliv na mechanické vlastnosti i orientace vzorku. Na Obr. 6 je uvedena závislost napětí–deformace pro podélný a obvodový směr u aorty. Z této závislosti vyplývá, že mez pevnosti v tahu a nejvyšší maximální deformace jsou vyšší v obvodovém směru než v podélném [6].



Obr. 6: Závislost napětí – deformace aorty pro podélný (a) a obvodový (b) směr.

2.5.4 Vliv věku

Vliv věku je jeden z nejdůležitějších faktorů. Hlavní komponentou, která má vliv na tuhost cévní stěny je obsah kolagenu. Čím vyšší je obsah kolagenních vláken, tím je stěna tužší. Naopak je tomu u elastických vláken. Poměr obsahu kolagenních a elastických vláken věnčitých tepen s věkem roste. Ideální pevnostní a deformační vlastnosti u věnčitých tepen jsou u mužů do 40 let a u žen do 50 let. Poté dochází ke snížení deformovatelnosti a ke zvýšení světlosti měřených úseků. Mez pevnosti s věkem klesá 2krát až 2,5krát. Z Tab. 3 vyplývá, že největší pokles s přibývajícím věkem je u maximálního protažení [6].

Tab. 3: Tahové mechanické vlastnosti koronární tepny.

Věk (roky)	10–19	20–39	40–59	60–79
Tahová síla do porušení na jednotku tloušťky (Nmm ⁻¹)	0,85±0,03	0,82±0,02	0,82±0,02	0,79±0,03
Mez pevnosti v tahu (MPa)	1,40±0,03	1,14±0,09	1,04±0,05	1,04±0,05
Maximální protažení (%)	99±2	78±2	68±4	45±4


2.5.5 Vliv teploty a rychlosti zatěžování

Vliv teploty na cévy se projevuje dvojím způsobem. Za prvé jsou podrážděny termoreceptory a termoregulace je prováděna pomocí nervové soustavy. Za druhé se mění mechanické vlastnosti jednotlivých složek, ze kterých je stěna cévy složena. Zde se jedná o odezvu pasivní. Aktivně reaguje pouze ta část, která obsahuje vlákna hladkého svalstva. S klesající teplotou modul pružnosti stěny aorty roste. Tento nárůst se děje na úkor deformovatelnosti. Při nízkých teplotách se stěny cév stávají křehké. Obecně platí, že při zvyšování teploty se tkáň smršťuje. Bylo však zjištěno, že u vzorků žil, šlach a svalů

dochází se vzrůstající teplotou k jejich prodlužování. Tyto rozdílné vlastnosti souvisí se změnou obsahu kolagenu a elastinu v příslušné tkáni [6].

2.5.6 Vliv aterosklerózy

Ateroskleróza obvykle vzniká v místech odstupů velkých tepen nebo v místě ohybu tepny. Projevuje se nahromaděním vaziva a tuku ve stěnách tepen, což je viditelné na Obr. 7. Stěny nabývají na objemu a tím dochází ke snížení průtoku tepny až do jejího uzavření. Tloušťka napadené vrstvy i zbytku stěny s věkem roste. Mez pevnosti v tahu s věkem klesá a je vyšší u části napadené aterosklerózou [6].



Obr. 7: Vlevo zdravá céva, vpravo postižená céva aterosklerózou, upraveno podle [8].

3 Algoritmy pro extrakci parametrů, hodnotících geometrii objektů z obrazu

V Matlabu pro výpočet parametrů hodnotících geometrii objektů v obraze existuje funkce *regionprops*, která pracuje s binárním obrazem. U binárních obrazů je objektu přiřazena 1 a 0 náleží pozadí, přičemž hodnoty 0 jsou ve výpočtech ignorovány.


Funkce *regionprops* slouží k měření vlastností objektů v určité oblasti obrazu a reprezentuje výsledek jako pole. Lze nastavit 2 různé typy parametrů, a to „basic“ a „all“. Pokud se nastaví vlastnosti parametru „basic“, pak funkce vrátí tři naměřené parametry: oblast, centroid (střed objektu) a ohraničující rámeček. Jestliže se nastaví vlastnost parametru „all“, funkce vypočítá všechna měření tvaru a v případě obrázků ve stupních šedi také hodnoty pixelů [18].

Pomocí funkce *regionprops* lze měřit mnoho parametrů, z nichž některé jsou uvedeny níže.

Tab. 4: Vybrané parametry pro hodnocení geometrie objektů.

Perimeter	Získává obvod výpočtem vzdáleností mezi každou sousední dvojicí pixelů kolem hranice oblasti.
MaxFeretDiameter	Maximální průměr Feretu měřený jako maximální vzdálenost mezi jakýmkoli dvěma hraničními body.
MaxFeretAngle	Úhel maximálního průměru Feretu vzhledem k vodorovné ose obrazu.
EquivDiameter	Průměr kruhu se stejnou oblastí jako region, vrácený jako skalár. Vypočteno jako $\sqrt{4 \cdot \text{Area} / \pi}$.
Circularity	Určuje kruhovitost objektů. Struktura obsahuje hodnotu kruhovitosti pro každý objekt ve vstupním obraze. Pro dokonalý kruh je hodnota kruhovitosti 1.
Area	Celková plocha detekovaného objektu v pixelech.
Centroid	Těžiště regionu.

Další funkcí pro hodnocení geometrie objektů v Matlabu je *imgradient*, která najde velikost gradientu a směr 2-D obrazu. Gradient (Obr. 8) je obecně směr růstu [19].



Obr. 8: Ukázka gradientu [20].

Syntaxe: $[Gmag, Gdir] = imgradient(I)$
 $[Gmag, Gdir] = imgradient(I, method)$
 $[Gmag, Gdir] = imgradient(Gx, Gy)$

Vstupní parametry:

<i>I</i>	vstupní obraz ve stupních šedi nebo binární obraz
<i>method</i>	operátor přechodu (Sobel – výchozí, Prewitt, Central a další)
<i>Gx</i>	horizontální gradient, zadaný jako numerická matice. Vodorovná osa x ukazuje ve směru rostoucího sloupce.
<i>Gy</i>	vertikální gradient o stejné velikosti matice jako <i>Gx</i> . Svislá osa y ukazuje ve směru rostoucího počtu řádků.

Výstupní parametry:

<i>Gmag</i>	číselná matice gradientu velikosti o stejném rozměru jako vstupní obraz <i>I</i> nebo směrových gradientů <i>Gx</i> a <i>Gy</i>
<i>Gdir</i>	směr přechodu, vrácený jako numerická matice velikosti přechodu <i>Gmag</i> . <i>Gdir</i> obsahuje úhly ve stupních o rozsahu $[-180, 180]$ měřené proti směru hodinových ručiček od kladné osy x.

4 Rešerše metod pro sledování dynamických objektů

Sledování objektů je oblast v rámci počítačového vidění, která má mnoho praktických aplikací, jako je video dohled, interakce člověk–počítač a navigace robotů. Schopnost sledovat objekt ve videu závisí na mnoha faktorech, jako jsou znalosti o cílovém objektu, typu sledovaných parametrů a typu videa.

Při analýze videa existují 3 základní kroky:

1. detekce objektů
2. sledování objektů
3. rozpoznávání aktivit objektů

Pokud jde o sledování objektů, existuje mnoho různých algoritmů, které lze rozdělit do 3 hlavních kategorií, a to sledování bodů, sledování jádra a sledování siluety. Jiné způsoby metody kategorizace jsou sledování na základě regionů, sledování podle kontur a sledování založené na hranicích [9].

4.1 Proces sledování

Sledování objektů se ukázalo jako jeden z nejpobulárnějších výzkumných předmětů v oblasti počítačového vidění. Přestože se jedná o dobře prozkoumaný problém, zůstává výzvou v mnoha aspektech. Sledované objekty, které mění vzhled v důsledku světelných změn, šumu a složitějšího pohybu, jsou považovány za náročný proces [9].

4.1.1 Zobrazení tvaru

Běžné způsoby použití segmentace tvaru zahrnují body, geometrické tvary, siluety, kontury. Tyto reprezentace tvaru spolu se stručným popisem oblasti použití jsou uvedeny níže.


BOD – předmět zájmu je reprezentován jediným bodem nebo sadou bodů. Použití sady bodů k reprezentaci objektů může být při sledování problematické v případě interakce mezi objekty, popř. okluze. Sledováním toho, který bod náleží ke kterému objektu, lze snadno způsobit nesprávnou detekci. Z tohoto důvodu je vhodnější malé objekty zastoupit jedním bodem.

GEOMETRICKÉ TVARY – pro reprezentaci tvaru (Obr. 9) se používají primitivní geometrické tvary, jako je obdélník nebo elipsa. Používání jednoduchých tvarů je běžný princip pro pevné i pružné předměty, je ale vhodnější pro jednoduché pevné předměty.

SILUETA A OBRYS – použití obrysu nebo hranice objektu k jeho reprezentaci se nazývá segmentace kontury.

KLOUBOVÉ TVAROVÉ MODELY – lze použít například při zastupování člověka u částí jako hlava, trup, paže, ruce. Každá část může být reprezentována pomocí jednoduchých geometrických tvarů.

SKELETÁRNÍ MODEL – použití siluety objektu a použití transformace střední osy umožňuje extrahovat kostru objektu [9].



Obr. 9: Reprezentace objektů. a) Centroid, b) více bodů, c) obdélník, (d) elipsa, (e) tvarové modely, (f) kostra objektu, (g) úplný obrys objektu, (h) kontrolní body na obrysu objektu, (i) silueta objektu.


4.1.2 Zobrazení vzhledu

Podobně jako reprezentace tvaru existuje celá řada způsobů reprezentace objektu pomocí vzhledu. Některé běžné způsoby reprezentace používají pravděpodobnostní hustoty, šablony nebo modely aktivního vzhledu. K tvorbě šablon se používají siluety nebo jednotlivé geometrické tvary [9].

4.1.3 Metody extrakce příznaků

Důležitou součástí sledování objektů je výběr vlastností objektu, díky nimž je objekt rozlišitelný. Tento proces se obvykle provádí manuálně. Například hrany se používají jako funkce při použití reprezentace na základě kontur.

HRANY – Hranici mezi objektem a pozadím lze obvykle snadno rozlišit. Použití hran jako reprezentující funkce pak umožňuje sledovací algoritmy, které sledují hranice objektu. Ukázka detekce hran je znázorněna na Obr. 10. Hrany jsou méně citlivé ke změnám osvětlení než například barva.



Obr. 10: Vlevo aorta na snímku z MR, vpravo detekce hran aorty, upraveno podle [10].

OPTICAL FLOW – Optický tok je vizuální jev, který zažívají téměř všichni lidé každý den. Výpočet zdánlivého pohybu se provádí identifikací pohybu každého pixelu mezi snímky. V těchto výpočtech se používá omezení jasu, což znamená, že odpovídající pixely v různých rámcích jsou odolné jasu. Tato metoda je více rozebrána v kapitole 4.2.4.

BAREVNÉ SPEKTRUM – Obvykle je barva reprezentována RGB (červená, zelená, modrá), někdy ale také YCbCr a HSV. Problémem je citlivost na změny osvětlení, protože barva je ovlivňována faktorem osvětlení. Kromě osvětlení je barva ovlivněna také odrazivostí objektu [9]. Detekce barevného spektra je dále rozebrána níže.

4.2 Detekce objektů

Aby bylo možné sledovat libovolný objekt, musí být nejprve detekován. Existují 2 různé přístupy. Detekce lze provést v každém snímku nebo při prvním objevení objektu ve videu.

4.2.1 Bodové detektory

Tato metoda se týká detekce zájmových bodů v obrazech. Zájmový bod by pokud možno měl být stabilní při změnách osvětlení scény a pohledu kamery. Bod zájmu může být konec čáry, bod maxima na křivce, roh atd. Existuje mnoho různých metod pro detekci bodu, kde jedna z nejvíce populárních metod je Harris detektor, který existuje v několika variantách. Detekce se provádí výpočtem z vlastních čísel určité matice, kterou lze považovat za rozptylovou matici gradientu obrazu vypočítanou v malé oblasti obrazu [9].

4.2.2 Frame differencing

Metoda frame differencing detekuje pohybující se objekt pomocí rozdílu mezi dvěma po sobě následujícími snímky. Nejčastěji používaný postup využívá operaci odečítání obrazu, kde se výstupní obraz získá odečtením druhého obrazového rámce od prvního v po sobě jdoucích snímcích. Nevýhodou této metody je nedosažitelnost úplného obrysu objektu.

Rozšířením této metody je metoda *three frame differencing*. Kombinuje two frame differencing s logickou operací „AND“ a uloží se jako snímek popředí.

Jednotlivé kroky metody three frame differencing jsou následující:

- Vyberou se postupně 3 snímky ze sekvence snímků

$$I_{t1}(x; y), I_t(x; y), I_{t+1}(x; y) \quad (4.1)$$

- Získá se rozdíl mezi prvním a druhým rámcem a pojmenuje se výstupní obraz jako

$$D1(x; y), tj. D1(x; y) = I_t(x; y) - I_{t+1}(x; y) \quad (4.2)$$

- Vypočítá se rozdíl mezi druhým a třetím rámcem a pojmenuje se výstupní obraz jako

$$D2(x; y), tj. D2(x; y) = I_{t+1}(x; y) - I_t(x; y) \quad (4.3)$$

- Vypočte se logické OR pixelů D1 a D2 k dosažení obrazu popředí

$$D(x; y), tj. D(x; y) = D2(x; y) | D1(x; y) \quad (4.4)$$

- Použije se Mediánový filtr pro odstranění šumu pozadí.



Obr. 11: Původní video.



Obr. 12: Two frame differencing.



Obr. 13: Three frame differencing.

Z výsledků na Obr. 11Obr. 12Obr. 13 je zřejmé, že metoda dvou rámců má velký problém s dírami v obraze a detekovaný objekt je přesnější s metodou tří rámců [11].

4.2.3 Background subtraction

Metoda odečítání pozadí je široce používaným přístupem pro detekci pohybujících se objektů ze statických kamer. Základním principem této metody je oddělení popředí od pozadí jednotlivých snímků. Pozadí představuje scénu, ve které nejsou žádné pohyblivé objekty. Opakem je popředí, které je tvořeno pohybujícími se objekty. Pozadí funguje jako reference a je určeno při počátku. Každý snímek je porovnán s pozadím tak, aby bylo možné rozpoznat změny v obraze. Porovnáním každého snímku na pozadí modelu je možné rozpoznat pohybující se objekty z hlediska odchylek od referenčního modelu. Metoda je však citlivá na změny prostředí, předpokládá pouze statické prostředí. Tuto nevýhodu lze potlačit tím, že referenční snímek se bude po nějaké době aktualizovat.


Makito Seki a spol. (2000) v [12] představují metodu odebírání pozadí jako účinný nástroj pro detekci pohybujících se objektů ve videosnímkech. Autoři zde navrhuji úpravu metody tak, že robustně zpracovává různé změny v pozadí, kdy se tato metoda adaptivně učí chronologickým změnám pozadí

pozorované scény z hlediska distribuce obrazových vektorů. Výsledkem je vyjádření skutečné změny na pozadí pomocí vícerozměrného obrazového vektorového prostoru což umožňuje detekci objektů se správnou citlivostí.

Mingyang Yang (2014) v [13] využívá Surendrovy metody odebrání pozadí doplněné o algoritmus diferenciací rámce (frame differencing algorithm) pro aktualizaci celého systému. U této metody se vycházelo z předpokladu, že všechny snímky, které se budou dále zpracovávat, jsou snímány kamerou. Rozdílový obraz $D_k(x, y)$, který je využíván pro detekci pozorovaných objektů lze definovat jako:

$$D_k(x, y) = \begin{cases} 1 & |I_k - I_{k-1}| > T_d \\ 0 & |I_k - I_{k-1}| \leq T_d \end{cases} \quad (4.5)$$

kde I_k je intenzita snímku a T_d je předem definovaná prahová hodnota. Účinnost navrhované metody byla ověřena na videozáznamu s letící včelou. Úspěšná detekce malého, rychle se pohybujícího objektu (včely) potvrzuje kvalitu navrhované metody.



Obr. 14: Výsledky navrhované metody bez binarizace.

Po aplikaci Surendrovy metody odebrání pozadí byl získán velmi jasný obraz pohybujícího se objektu (viz Obr. 14) bez binarizace. Z důvodu odstranění šumu ze snímku, který může být způsobený např. prouděním vzduchu nebo změnami intenzity světla, je na snímek po aplikaci navrhované metody dále aplikovaná binarizace, diferenciací obrazu a dále morfologické filtry pro získání ještě lepšího výsledku.

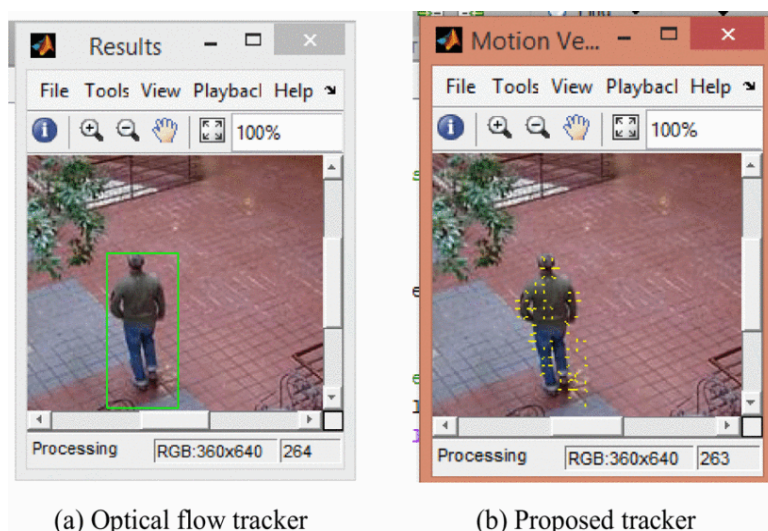
4.2.4 Optical flow

Optický tok je velmi populární technika ve sledování pohybujících se objektů. Tato metoda poskytuje informace o změnách obrazu v čase dt . Optický tok je užitečný pro sledování objektů, pokud jsou snímky napřed filtrovány proti šumu. Pro jeho odstranění jsou snímky filtrovány pomocí mediánové filtrace. Po filtraci je aplikováno prahování, aby byly odstraněny nežádoucí objekty z detekovaného objektu. Celé blokové schéma je zobrazeno na Obr. 15.



Obr. 15: Rámec algoritmu.

Hlavním cílem odhadu optického toku je oddělit pohybové objekty popředí od pozadí a generovat vektor optického toku pro pohybující se objekty. Optický tok počítá pohyb mezi po sobě jdoucími snímky. Objekt je posunut o vzdálenost dx ve směru x a dy ve směru y v čase dt . Předpokládá se, že jas pozadí zůstane konstantní. Dynamický obraz lze popsat jasovou funkcí $I(x, y, t)$. V odhadu optického toku jsou k dispozici různé metody. Velmi používaný přístup ke stanovení optického toku je zavádění intenzity pixelu na pozici $[x, y]$ v čase t jako $E(x, y, t)$. Jednotlivé rychlosti jsou vyjádřeny jako $u = dx/dt$, $v = dy/dt$. Cílem je určit rychlost u a v pro každý bod. Metodu optického toku lze použít jak pro pohybující se kameru, tak i pro statickou. Nevýhodou Optical flow je její pomalost [14].



(a) Optical flow tracker

(b) Proposed tracker

Obr. 16: Vlevo optical flow detektor, vpravo navržený detektor.

4.3 Sledování objektů

Existuje mnoho různých algoritmů, které se používají pro účely sledování objektů. Některé zpracovávají pouze sledování 1 objektu, zatímco jiné pracují tak, aby bylo možno sledovat více objektů. Algoritmy používané pro sledování objektů mohou být rozděleny do několika kategorií. Nejčastěji se dělí na 3 skupiny, a to sledování bodů, jádra a siluety [9].

4.3.1 Sledování bodů

Sledování bodů se používá, pokud jsou detekované objekty reprezentovány body. Obecně lze říct, že sledování se provádí hodnocením objektu z hlediska pozice a pohybu. Sledování je možné přidružením bodů napříč rámci. Přidružením v jednom rámci do jiného je založeno na předchozím stavu objektu. Tento algoritmus není citlivý na změny osvětlení, ale nevýhodou jsou problémové oblasti při manipulaci s okluzí (zejména u objektů reprezentovaných více body). Existují 2 metody.

Deterministická metoda – při použití dané počáteční podmínky nebo počátečním stavu bude deterministický model produkovat stejný výstup. Tato metoda je vhodná pro objekty, u kterých lze

předvídat cesty pomocí prototypu trajektorie. Lidé jsou například vhodnější pro sledování touto metodou než zvířata, protože zvířata se pohybují nepředvídatelným způsobem, což ztěžuje vytvoření prototypu.

Statistická metoda – modelování je považováno za složitější než deterministická metoda. Tato metoda spoléhá na pravděpodobnost pohybu objektu. Tato metoda je vhodná, pokud je přítomen šum při měření. Nevýhodou je složitější modelování než v případě deterministické metody [9].

4.3.2 Kernel tracking

Tato metoda je založena na výpočtu pohybu reprezentovaného objektu pomocí oblasti primitivních objektů. Použitím pohybového modelu, tj. výpočtem pohybu objektu z jednoho snímku do druhého je možno určit jeho další polohu.

Tento algoritmus se liší

v závislosti na tom, zda se jedná o jeden nebo více sledovaných objektů. U sledování jednoho objektu mohou být odlišné prvky, jako barva nebo intenzita, používány k vytvoření šablony. Základní přístup pro tuto metodu je vyhledat konkrétní šablonu v obraze. Jedná se o časově náročnou metodu.

Sledování více objektů je složitější úkol, kdy je potřeba vzít v úvahu faktory jako interakce mezi objekty a pozadím. Problém je, pokud jeden objekt částečně nebo úplně překryje jiný objekt. Jeden z návrhů na odstranění tohoto problému je považovat obraz za sadu vrstev, kde počet sledovaných objektů určuje počet vrstev v obraze. Metoda také zahrnuje další vrstvu pozadí. Další navrhovanou metodou je použití Bayesovské teorie rozhodování. To se provádí pomocí intenzity barev a barevný histogram jako reprezentace prvků a skóre podobnosti pro každý detekovaný pár. Pokud je odpovídající skóre vyšší než určitá prahová hodnota, šablona bude aktualizována. Pokud je skóre nižší než prahová hodnota, objekt je dále vyšetřován, aby se zjistilo, zda došlo k okluzi. Objekt je rozdělen do několika dílčích částí a pro tyto části se vypočítá skóre podobnosti. Tato metoda nefunguje, pokud je objekt zcela překryt.

Přístup pro sledování jádra je založen na výpočtu pohybu objektu. Výpočtem pohybu objektu z jednoho snímku do druhého je možné určit jeho další pozice. Tato metoda je vhodná pro jednoduché tvary [9].

4.3.3 Sledování siluety

Tato metoda je nazývána sledováním regionů. Zastupování objektů jednoduchými geometrickými tvary mohou být pro některé složitější objekty nedostatečné, např. ruce a hlava. S metodou siluety je možné získat přesný popis tvaru [9].

5 Sledování geometrických vlastností

V této kapitole jsou popsány metody použité v této práci pro sledování geometrických vlastností objektů z video signálu. Jedná se o metodu detekce barevného spektra a metodu distribuce tloušťky aorty.

5.1 Detekce barevného spektra

Autoři článku [15] detekovali plamen na základě jeho charakteristické barvy. Výhodou této metody je její nízká výpočetní náročnost. Omezením metody je změna jasu, kterou vznikají falešné tóny červené. Tento problém lze zmírnit přepnutím modelu z RGB do YUV. Tím se ovšem zvýší výpočetní náročnost. Dalším problémem můžou být falešné předměty s totožnou barvou, jako je plamen. Řešením problému je předpoklad, že oheň mění neustále svůj tvar.

Jak už bylo řečeno, barva je detekována v modelu YUV. Tento model odděluje jas od chrominance a je tak méně citlivý na změnu jasu. Myšlenka metody je založena na tom, že ve většině plamenů vykazují pixely hodnotu červeného kanálu větší než u zeleného, stejně jako hodnota zeleného kanálu je větší než modrého kanálu.


$$R(x, y) > G(x, y) > B(x, y) \quad (5.1)$$

Takové podmínky jsou vyjádřeny v modelu YUV, takže získáme pro obecný pixel (x, y) :

$$r_1^c: Y(x, y) > U(x, y) \quad (5.2)$$

Implementace algoritmu běží v reálném čase s frekvencí snímků přibližně 3 snímky/s. Široká sbírka videí obsažená v tomto článku obsahuje požáry natočené v různých podmínkách a prostředích, doplněné o videa s imitací ohně. To umožnilo ověřit robustnost systému s ohledem na falešné pozitivní hodnoty.


Autoři článku [16] využívají metodu detekce barvy v RGB modelu. RGB model charakterizuje červenou, zelenou a modrou barvu. Volba RGB zjednodušuje algoritmus a design systému. Tato metoda byla navržena rovněž pro real-time sledování objektu (viz Obr. 18).



Obr. 17: Blokové schéma algoritmu.

Blokové schéma algoritmu je znázorněno na Obr. 17. Nejprve je získán videozáznam. Poté se provede dekompozice na jednotlivé obrazy, ze kterých na základě odlišného barevného spektra probíhá extrakce prvků. V posledním kroku se objekt na základě odlišných vlastností detekuje. Pokud se objekt pohybuje, mění se poloha detekované oblasti.

Navrhovaný algoritmus se skládá z několika kroků. Nejprve je vybráno počátečního umístění vyhledávací šablony T objektu. Následně je vypočítán histogram pro $p = \frac{h_T}{|T|}$, kde h_T je histogram šablony T a $|T|$ je počet pixelů. Histogram najde umístění objektu přes vyhodnocení míry podobnosti histogramu šablony a histogramu videa. Nakonec je použit mediánový filtr na odstranění šumu.



Obr. 18: Sledování pohybu bílého míčku.

5.2 Skeleton

Středové linie krevních cév jsou užitečnými nástroji pro provádění důležitých anatomických měření (délka, průměr, plocha), které nelze pomocí 2D obrázků přesně získat. Autoři v článku [17] představují novou metodu pro středovou extrakci cévních stromů. Použitím výpočetní dynamiky tekutin (CFD) lze získat středovou čáru (viz. Obr. 19), což umožňuje lepší měření než klasické čistě geometrické středy.



Obr. 19: Vlevo 3D model cévy, vpravo středová čára.

Prvním krokem pro měření anatomických markerů je použití 1D schématu cévy zvané středová čára, která může být definována jako křivka vystředěná uvnitř cévy. Středová čára může být hlavním nástrojem používaným k provádění jakýchkoli anatomických měření na cévách nebo tubulárních strukturách, protože poskytuje snadno použitelné znázornění. Umožňuje výpočet důležitých parametrů, jako je průměr a plocha, nebo procento arteriální stenózy (zúžení).

Bylo provedeno několik principů pro vyvinutí automatického extrakčního algoritmu středové linie. Nejzákladnějším přístupem je ruční vymezení osy. To je prováděno manuálním výběrem centroidů zájmových oblastí (ROI) v každém řezu a interpolací takto získaných bodů. Tento proces je velmi časově náročný a nezaručuje přesnou středovou čáru, pokud analyzované průřezy nejsou kolmé na směr skenování.

Jedním z prvních typů automatických technik pro extrakci středové čáry bylo topologické ředění, které spočívá v odstranění pixelu ROI prováděného podle předdefinovaných pravidel, dokud není získán jeden pixel. Použitá pravidla se liší podle algoritmu, ale obvykle musí ředění zachovat alespoň koncové body (pixely použité jako reference) a jednoduché body (pixely, jejichž odstranění by

změnilo topologii ROI). Tato metoda je citlivá na chyby v segmentované oblasti zájmu a neposkytuje vždy dobrou aproximaci středové linie. Topologické ztenčení je také časově náročné.

Jiná skupina metod použila Voronoiho diagram. Okraje Voronoiho diagramu, které leží uvnitř polygonálního tvaru, se používají jako aproximace středové linie a čím více je hraničních vrcholů, tím více řešení konverguje ke skutečné středové linii. Tato metoda je však citlivá na mezní šum.

Vytvořený algoritmus extrakce středové linie, znázorněn na Obr. 20 je popsán následovně:

1. Inicializace: algoritmus vybere jako počáteční bod P_1 . Nechť v_1 je vektor rychlosti v tomto bodě a π_1 kolmice.

2. Propagace: středová čára je vytvořena iterativně vytvořením řady bodů P sledujících maximální umístění toku rychlosti po proudu. Předpokládejme, že sady trojic (P_1, v_1, π_1) až (P_n, v_n, π_n) jsou známy. Další triplet je definován takto:

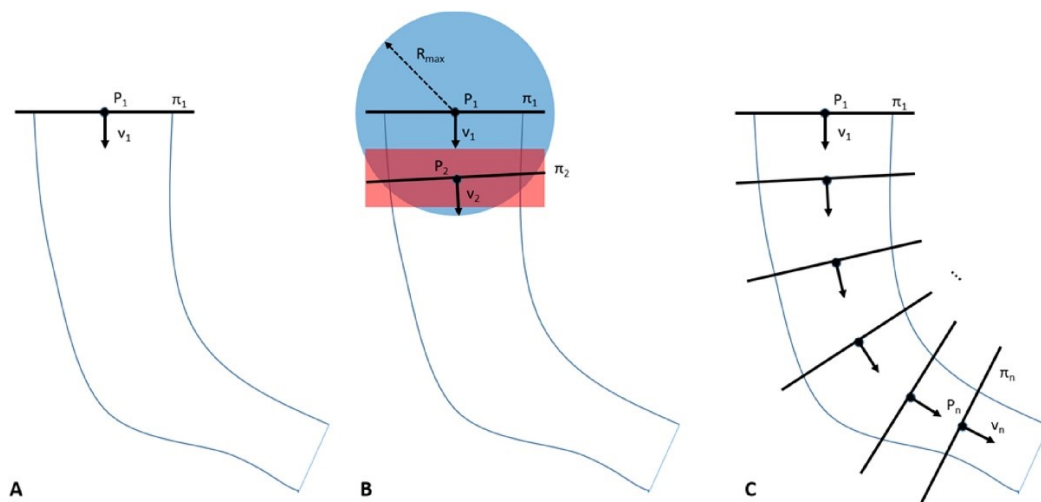
a) sekce objemu, která byla použita k vyhledání P_{n+1} (zájmová sekce), definujeme jako průnik dvou sad bodů: bodů ve vzdálenosti R_{\max} od P_n a bodů poloprostoru označeného v_n jehož vzdálenost je $d_{\min} > 0$ a menší než d_{\max} ; tyto dvě vzdálenosti jsou upraveny tak, aby se zajistilo, že v zájmové sekci existuje alespoň jedna síť konečných prvků;

b) vybereme podmnožinu bodů tohoto objemu s nejvyšší rychlostí;

c) Definujeme P_{n+1} jako průměrnou pozici těchto bodů a v_{n+1} jako průměr rychlostí vypočítaných v těchto bodech;

d) π_{n+1} je definována jako rovina kolmá k v_{n+1} , která prochází P_{n+1}

3. Kritéria zastavení: algoritmus se opakuje, dokud není dosaženo výstupu z cévy.



Obr. 20: Algoritmus extrakce středové linie: A) Inicializace algoritmu; B) oblast zájmu je průsečík modrého kruhu s červeným obdélníkem; C) Algoritmus se opakuje, dokud není nalezen poslední bod středové linie.

6 Design algoritmizačních procedur pro detekci a sledování

Tato kapitola se věnuje návrhu a řešení algoritmu pro detekci geometrických parametrů z video signálu. V rámci analýzy jsou diskutovány dva variabilní přístupy pro detekci zájmových objektů z videa. Jedná se o algoritmus pro detekci barvy a metodu, která je založena na měření distribuce tloušťky cévního segmentu.

6.1 Support Package for USB Webcams

Jelikož v práci je řešena real-time detekce geometrických parametrů, je zapotřebí zmínit princip připojení webové kamery. Připojení webové kamery je uskutečněno instalací *Support Package* v Matlabu. Tento balíček zahrnuje webové kamery, které jsou zabudovány do notebooků, nebo kamery připojující se k počítači pomocí USB.

6.1.1 Webcamlist

Funkce *webcamlist()* vrátí seznam dostupných webkamer připojených k našemu počítači. Funkce slouží k ověření propojení kamery s Matlabem. Níže je uveden příklad, kde návratovou hodnotou je řetězec obsahující název kamery *EasyCamera*.

```
ans =  
  
    {'EasyCamera'}
```

6.1.2 Webcam

Pomocí funkce *webcam()* se vytvoří spojení s webovou kamerou v našem systému. Do závorky se zapíše číslo udávající pořadí kamery z funkce *webcamlist()*, kterou chceme připojit. Funkce spustí danou kameru a po uložení do proměnné můžeme s touto kamerou dále pracovat. Příkaz vypíše do Command Window parametry uvedené níže.

```
webcam(1)  
ans =  
webcam with properties:  
  
    Name: 'EasyCamera'  
    Resolution: '1280x720'  
    AvailableResolutions: {1x9 cell}  
    Hue: 50  
    Sharpness: 50  
    Gamma: 50  
    Contrast: 50  
    Saturation: 50  
    Brightness: 50
```


Vysvětlení jednotlivých parametrů:

- Name – název webové kamery, specifický pro každou kameru,
- Resolution – rozlišení videa, které lze změnit,
- AvailableResolutions – dostupné rozlišení webové kamery,
- Hue – nastavení odstínu obrazu, rozsah může být nastaven od 0 do 100,

- Sharpness – ostrost obrazu, rozsah od 0 do 100,
- Gamma – nastavení gama korekce v rozsahu od 0 do 100,
- Contrast – kontrast obrazu, rozsah od 0 do 100,
- Saturation – nastavení saturace neboli množství použité barvy v obraze, rozsah 0-100,
- Brightness – změna jasu v obraze, rozsah od 0 do 100.

6.2 Měřicí řetězec

Kardiovaskulární systém je jeden z nejsložitějších systémů v lidském těle. Zúžení tepny v srdci nebo vysoký krevní tlak může oslabit srdce natolik, že nebude schopno pumpovat krev do celého krevního oběhu. Proto je dobré měřit krevní tlak v reálném čase a dlouhodobě sledovat stav kardiovaskulárního systému. Model kardiovaskulárního systému slouží k provedení testu v bezpečných podmínkách. Vytvořený model by měl být schopen reprodukovat fyziologický signál a napodobovat skutečný kardiovaskulární systém. Není možné vytvořit model kardiovaskulárního systému zahrnující všechny cévy s jejich parametry, proto je nutné provést určitou aproximaci některých částí kardiovaskulárního systému. Schéma měřicího řetězce je uvedeno na Obr. 21.



Obr. 21: Měřicí řetězec modelu pro měření distribuce tloušťky.

Model aorty (viz. Obr. 22) byl vytvořen ze snímků magnetické rezonance skutečné aorty a poté vytištěn do 3D modelu. Aortální segment byl vyroben ze dvou částí s odlišnou tuhostí, z nichž jedna byla vyrobena ze silikonu a druhá z PVC. Silikon byl vybrán proto, že tento typ materiálu má nejbližší vlastnosti ke skutečným tkáním krevních cév. PVC a teflonové materiály s různou poddajností simulují patologie arteriálních segmentů. Plastová část je potažena tekutým silikonem. Poté co silikon ztuhne, je plastová část odstraněna.



Obr. 22: Model aorty zapojený v měřícím řetězci.

Pro reprodukci pulzního toku v lidském těle bylo použito pulzační čerpadlo, které se v současné době používá v klinických situacích jako vnější srdce. Tento typ pumpy může simulovat srdce většího zvířete. Odolnost žilního systému je simulována nastavitelným ventilem. Žilní strom byl jednoduše modelován rezervoárem naplněným kapalinou (viz. Obr. 23). Použitou kapalinou byl roztok 60 % vody a 40 % glycerinu.



Obr. 23: Měřící řetězec s pulzačním čerpadlem a rezervoárem naplněným kapalinou.

Systém byl validován a porovnán se skutečným lidským kardiovaskulárním systémem. Je menší než skutečný kardiovaskulární systém, ale parametry každé části byly nastaveny tak, aby odpovídaly skutečnému lidskému tělu.

6.3 Charakteristika dat použitých k analýze

Pro tuto práci bylo použito 7 videí. Video byla natáčena 18 Mpix kamerou se stativem a snímková frekvence byla 25 snímků/min. Natočené video bylo rozděleno na framy. Pro snížení výpočetní náročnosti bylo u všech videí zvoleno 252 framů, což je asi 10 s videa. Přehled použitých dat k analýze je uveden v Tab. 5. U Video2 a Video6 se nepodařilo zjistit počet framů z důvodu velké výpočetní kapacity. Rozlišení videa 1080x1920 se řadí mezi full HD rozlišení a patří k nejpodporovanějším rozlišením. K ještě většímu snížení výpočetních nároků je zapotřebí podvzorkování (více v kapitole 6.4.1), které ovšem rozlišení sníží na 270x480. Toto rozlišení je ale dostačující ke správnému modelování dynamiky aorty.

Tab. 5: Přehled použitých dat.

	Délka videa [s]	Původní počet framů	Rozlišení nativních dat [px]	Rozlišení po podvzorkování [px]
Video1	51	1293	1080x1920	270x480
Video2	65	-	1080x1920	270x480
Video3	41	1035	1080x1920	270x480
Video4	40	906	1080x1920	270x480
Video5	40	903	1080x1920	270x480
Video6	56	-	1080x1920	270x480
Video7	41	1032	1080x1920	270x480



Obr. 24: Frame 10 z videa1.



Obr. 25: Frame 10 z videa2.



Obr. 26: Frame 10 z videa3.



Obr. 27: Frame 10 z videa4.



Obr. 28: Frame 10 z videa5.



Obr. 29: Frame 10 z videa6.




Obr. 30: Frame 10 z videa 7.

Na videu 2, 4 a 5 je vidět materiál, který degraduje kvalitu detekce a výpočet tloušťky aorty. Je velmi důležité, z jakého úhlu bylo video natočeno. Stíny z aorty a odlesky světla opět zhoršují kvalitu detekce při dalším zpracování.

6.4 Předzpracování obrazu

Prvním krokem je předzpracování obrazu. Cílem předzpracování je zlepšení vlastností snímků pro následnou segmentaci. V této práci je hlavním smyslem předzpracování nastavit jednotlivé funkcionality tak, aby byly na aortě co nejvíce potlačeny záblesky světla, které v segmentačním modelu degradují kvalitu detekce. Vhodným předzpracováním snímku se zvýší úspěšnost dalších kroků detekce a výpočet tloušťky aorty. Pro úpravu bylo využito podvzorkování obrazu a mediánová filtrace. Blokové schéma je uvedeno na Obr. 31.



Obr. 31: Blokové schéma kroků předzpracování obrazu.

6.4.1 Podvzorkování obrazu

Nevýhodou vstupních dat je velké množství nepotřebné obrazové informace, které zvyšuje časovou náročnost dalších operací, konkrétně modelu distribuce tloušťky aorty, aplikovaný v této diplomové práci.

Podvzorkování je provedeno pomocí funkce v Matlabu, která využívá bikubické interpolace s využitím antialiasingového filtru. V parametrech funkce je volena hodnota měřítka změny obrazu $m \in < 0; 1 >$ pro zmenšení, $m > 1$ pro zvětšení. Použitá funkce vrátí obrázek, který je x -krát větší nebo menší než originální snímek.

Redukcí obrazové matice se výpočetní nároky výrazně sníží. Tato operace však degraduje kvalitu obrazu. Je proto nutné najít kompromis mezi úrovní podvzorkování a kvalitou informace. Tabulka níže uvádí snížení výpočetních nároků pro 3 testovací videa. Jako nejideálnější byla vybrána velikost podvzorkování 1/4, kdy časová náročnost je malá a kvalita obrazu je uspokojivá pro následující

operace. U prvního videa se tak z původních 93 minut podvzorkováním snížila výpočetní náročnost na 3 minuty. Vliv podvzorkování na časovou náročnost modelu distribuce tloušťky je uveden v Tab 6.

Tab 6: Vliv podvzorkování na časovou náročnost.

	Velikost podvzorkování				
	Bez podvzorkování	1/2	1/3	1/4	1/5
Video 1	5592 s	892 s	345 s	183 s	118 s
Video 2	5338 s	1148 s	349 s	197 s	60 s
Video 3	8637 s	923 s	600 s	332 s	116 s

6.4.2 Mediánová filtrace


Mediánová filtrace je jedna z nejpoužívanějších filtrací v oblasti zpracování obrazu. Slouží k potlačení specifického šumu černých a bílých bodů v obraze a k vyhlazení obrazu. Základem je princip 2D cyklické konvoluce, kde je přikládána konvoluční maska na příslušné místo v obraze. Každý pixel překrytý tabulkou je vynásoben koeficientem v příslušné buňce a následně je proveden součet všech těchto hodnot. Tím je dosažen nový pixel.

Princip filtrace spočívá v posuvu okna masky po obraze a výběru mediánu z hodnot ležících pod touto maskou. Mediánový filtr vybere a seřadí obrazové body z okolí bodu podle intenzity a daný bod nahradí tou hodnotou, která je uprostřed poslopnosti intenzit jasu (medián). Pro jednoznačnost se volí lichý počet prvků. Pokud se vyskytne sudý počet prvků, vyberou se prostřední dva prvky a vytvoří se jejich aritmetický průměr. Mediánový filtr zachovává hrany při odstraňování šumu a nezpůsobuje jejich rozmazání, což je v tomto případě užitečné. Pro volbu mediánové filtrace byla zvolena funkce *medfilt2* s možností nastavení velikosti masky.

Tab. 7: Nastavení masky mediánového filtru.

	Velikost masky
Video1	10
Video2	15
Video3	10
Video4	20
Video5	30
Video6	10
Video7	30

V Tab. 7 je uvedeno nastavení velikosti masky pro každé video. Video pořízena pod špatným úhlem mají velikost masky větší než u videí, kde nejsou viditelné odlesky nebo stíny z aorty. Na Obr. 32 je ukázka provedení mediánové filtrace, kdy došlo k vyplnění děr v obraze.



Obr. 32: Původní binární snímek (nahore), snímek po aplikaci „medfilt2“ (dole).

6.5 Model distribuce tloušťky aorty

Tato kapitola se věnuje samotnému návrhu detekce kostry aorty pro výpočet její tloušťky. Řešení se skládá z jednotlivých podkroků, které budou v následujících kapitolách dále rozebrány.

6.5.1 Princip metody skeleton

Jedná se o metodu nalezení středové linie. Využívá se pro vyjádření podlouhlých objektů v obraze. Tato metoda ztenčí veškeré prvky v obraze na šířku jednoho pixelu. Skeletonizace se řadí mezi morfologické operace. Skeleton umožňuje zachycení topologických a geometrických vlastností tvaru objektu. Pro skeletonizaci je limitující citlivost na šum a nepatrné deformace na hranicích objektu. To může vést k větvení skeletonu a tím zkreslit informace o tvaru objektu.

Vzdálenostní transformace

Pomocí tohoto algoritmu je měřena vzdálenost na základě symetrických bodů, které mají od dvou různých hraničních bodů stejnou vzdálenost rovnou nejmenší vzdálenosti tohoto bodu od hranice objektu. Využívá se výpočet vzdálenostní mapy, který každému pixelu v obraze říká, jaká je nejkratší vzdálenost ke krajnímu (nulovému) pixelu. Ze vzdálenostní mapy se získá skeleton, tvořen body, reprezentující největší hodnotu vzdálenostní mapy. Tyto body udávají nejmenší možnou vzdálenost k okolí objektu [28].

Vzdálenostní mapa pracuje s binárním obrazem, kde pozadí má hodnotu 0 a objekt hodnotu 1. Detekce hranic aortálního segmentu je realizována Cannyho detektorem hran. Tento detektor pracuje v několika krocích. Pro eliminaci nežádoucího šumu v obraze je použit Gaussovský filtr. Po filtraci je určen gradient v každém pixelu pomocí první derivace. Následně jsou hledána lokální maxima a je provedeno prahování pro potlačení nevýznamných lokálních maxim gradientů.


Jeden ze základních prvků určování vzdálenosti v obrazové analýze je výpočet distanční matice. Tato matice formuluje nejmenší vzdálenost každého nulového pixelu k prvnímu nenulovému pixelu. Po

spočítání distanční matice mají pixely na okrajích objektu nejmenší vzdálenost k prvnímu pixelu, který charakterizuje pozadí. Oproti tomu pixely ve středu objektu mají největší vzdálenost od pozadí.

Algoritmus tedy lze shrnout do několika kroků:

1. *Detekce kostry aorty*
2. *Výpočet tečny a normály v kolmém směru* – na rovinu kostry aorty je spuštěna normála.
3. *Normála končí na hranici aorty* – hodnota vzdálenosti = 0, posun o jeden pixel ve směru ke kostře – hodnota vzdálenosti = 1, další posun – hodnota vzdálenosti = 2
4. *Kolmo po normále k bodu na kostře* – tam bude vzdálenost maximální
5. *Výsledkem poloměr tloušťky*
6. *Tak samo na druhou stranu* – kostra symetrická na 2 strany
7. *Vynásobení krát 2*
8. *Výsledkem tloušťka aorty*

Takto je spočten každý bod na kostře aorty. Ilustrativní obrázek principu algoritmu je uveden na Obr. 33.




Obr. 33: Princip vzdálenostní transformace.

Pro výpočet vzdálenosti mezi pixely je třeba definovat metrický systém. Euklidovská vzdálenost je definována vztahem:


$$D_e(A, B) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2} \quad (6.1)$$

neboli výpočtem pro přímou vzdálenost mezi dvěma pixely. Jedná se o nepřesnější možnost výpočtu dvou pixelů, které od sebe nejsou vzdáleny přímo v diagonálním směru [21].



Obr. 34: Euklidovská vzdálenost.

Výsledný frame po výpočtu distribuce tloušťky aorty je uveden na Obr. 35. Sytě modrá barva charakterizuje oblast mimo aortu, kde hodnota vzdálenostní transformace odpovídá nule. Čím více se blížíme ke kostře aorty, tím je barva světlejší. Žlutá barva charakterizuje hodnoty s nejvyšší hodnotou vzdálenostní transformace.




Obr. 35: Barevné mapování.

6.5.2 Implementace algoritmu v prostředí MATLAB

Vývojový diagram jednotlivých kroků algoritmu je uveden na Obr. 36. Z natočeného videa je nutné udělat framey, ze kterých je následně vypočítán průměr cévy. Toho lze dosáhnout online (např. <https://www.img2go.com/convert-to-jpg>), nebo přímo v Matlabu. Příklad kódu použitého v našem případě v Matlabu je zobrazen níže. Funkce *VideoReader* načte video, ze kterého se extrahují jednotlivé framey. Funkce *read* přečte všechny snímky z video souboru. Obsahuje pole dvou prvků, kde 1 znamená první číslo snímku a 252 představuje poslední snímek souboru.

```
v = VideoReader('aorta.mp4');
frame = read(v, [1 252]);
```



Obr. 36: Vývojový diagram kroků algoritmu.


Dalším krokem je binární segmentace obrazu. Segmentace obrazu znamená rozdělení obrazu na části, skládající se z pixelů podobných vlastností (barvy nebo jasu). Pro segmentaci obrazu bylo zvoleno prahování. Metoda prahování je založena na hodnocení jasu každého pixelu. Principem této metody je nalezení takového prahu v histogramu, pro který bude platit, že všechny hodnoty jasu nižší než práh, odpovídají popředí, naopak hodnoty vyšší než práh, odpovídají pozadí. V této práci byla z RGB obrazu vybrána modrá chrominanční složka, pro kterou bylo prahování řešeno. Prahování proběhlo experimentálně, přičemž práh byl stanoven na hodnotu 10. Hodnotám ležícím pod tímto zvoleným prahem bylo přiřazeno popředí, hodnotám nad prahem pozadí. V dalším kroku je řešen výpočet distribuce tloušťky aorty, jejíž princip je popsán výše.

6.5.3 Testování algoritmu na reálných datech

Tato část práce se věnuje testování na nativních a předzpracovaných snímcích. Algoritmus byl testován na sedmi videích.

Testování algoritmu na nativních snímcích

V testovací sadě jsou vybrány 3 snímky s podobnými vlastnostmi, bez větších odlesků na aortě.




Obr. 37: Testování na nativních snímcích: nativní snímky aorty (vlevo), binární model objektů zájmu (uprostřed) a skeletonizace aorty.

Na Obr. 37 jsou v levých oknech vidět nativní snímky aorty. V prostředním okně je zobrazen binární model objektů zájmu, v pravém okně je extrahován skeleton aorty. U žádného snímku se nepodařilo dosáhnout optimálních výsledků vzhledem k černým shlukům v binárním modelu, které souvisí se světelnými záblesky na aortě. To degraduje kvalitu detekce a následně výpočet tloušťky aorty.

Testování algoritmu na předzpracovaných snímcích

Pro testování na předzpracovaných snímcích byly nastaveny parametry:

- Úroveň podvzorkování: $1/4$,
- Velikost filtračního jádra mediánového filtru: 10.



Obr. 38: Testování na předzpracovaných snímcích: předzpracované snímky aorty (vlevo), binární model objektů zájmu (uprostřed) a skeletonizace aorty.

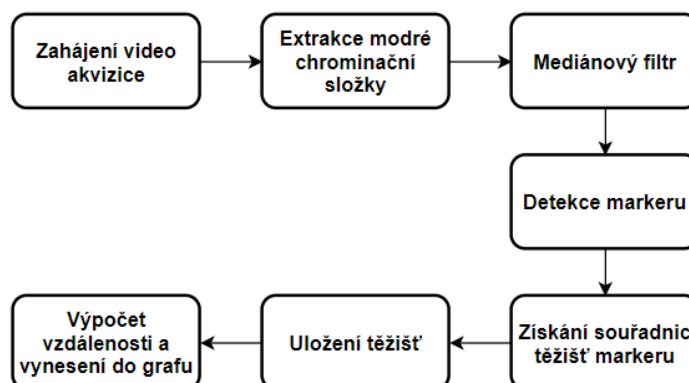
Na Obr. 38 je na snímcích v levém okně vidět předzpracované obrazy, na snímcích uprostřed je zobrazen binární model po aplikaci mediánového filtru a v pravém okně je extrahován skeleton aorty. Odlesky na aortě kompenzuje mediánový filtr a u všech snímků na obrázku proběhla detekce úspěšně.

6.6 Návrh a realizace algoritmu na základě detekce jasového spektra markeru

Druhou metodou navrženou pro tuto práci je algoritmus pro detekci barevného markeru. Tento algoritmus má jisté nevýhody, proto bude brán jako alternativní metoda.

Blokové schéma algoritmu je uvedeno na Obr. 39. Při návrhu algoritmu pro detekci objektu modré barvy, bylo vycházeno z teoretických poznatků, shrnutých v teoretické části této práce. Testovaný algoritmus funguje jak real-time, tak z již existujících záznamů, kde na vstupu je video soubor ve formátu .mp4. Po spuštění video souboru proběhne extrakce barvy. V tomto případě modré, ale lze zvolit i detekci červené nebo zelené barvy.

Dále je aplikován mediánový filtr pro odstranění šumu. Maska filtru byla nastavena na hodnotu 3. Poté jsou získány souřadnice těžišť barevných markerů pomocí funkce *regionprops()*, která je popsána v kapitole 3 a použita i pro získání skeletonu aorty. Následně jsou těžiště uložena do matice. Nakonec se vypočítá vzdálenost těchto těžišť, které jsou vyneseny v grafu v závislosti na čase.



Obr. 39: Blokové schéma algoritmu pro detekci daného objektu.

Pro detekci barvy je použita funkce `imsubtract()` v Matlabu. Ta je založena na odečtení každého prvku v obraze od druhého a vrátí rozdíl v odpovídajícím prvku obrazu. V tomto případě se odečte snímek ve stupních šedi od modré komponenty.

Na začátku algoritmu je nejprve proveden test správného nastavení detekované barvy v algoritmu. U každého detekovaného objektu se objeví modré ohraničení a souřadnice těžiště objektu (viz Obr. 40).



Obr. 40: Ověření správné detekce barvy testovaného algoritmu.

6.6.1 Testování odstínu modré barvy a velikosti markeru

V této kapitole byla prověřena závislost odstínu modré barvy na schopnostech algoritmu daný objekt detekovat. Bylo zjištěno, že odstín modré barvy ovlivňuje schopnost detekce objektů.


Nakreslení markerů modrým fixem na červenou cévu (Obr. 41) způsobilo, že marker vypadá jako černý a zde algoritmus nebyl schopen detekce. Bylo zapotřebí nalepení bílého podkladu na cévu, aby nedocházelo ke zkreslení barvy.



Obr. 41: Chybný odstín modré barvy.

Správná detekce markerů je viditelná na Obr. 42. Algoritmus byl testován jak na tmavý, tak na světlý odstín modré barvy. U obou markerů proběhla detekce úspěšně. Souřadnice X charakterizuje

horizontální směr a souřadnice Y směr vertikální. Následně pomocí uložených souřadnic je vypočítaná tloušťka aorty.



Obr. 42: Správná detekce modré barvy pro tmavě modrý i světle modrý marker.


Dalším důležitým parametrem je velikost markerů. Pokud je marker příliš velký, algoritmus ho detekuje jako více modrých markerů najednou. Takže místo dvou reálných markerů jsou chybně detekovány tři markery (viz Obr. 43).



Obr. 43: Chybná detekce v závislosti na velikosti modrých markerů.

6.6.2 Funkčnost algoritmu

V této kapitole je popsána funkčnost algoritmu pro detekci barvy na testovacím videu. Pomocí uložených těžišť byl vykreslen graf tloušťky v závislosti na čase (Obr. 44).



Obr. 44: Závislost tloušťky aorty na čase pro testovací video.

V testovacím videu nebyla aorta v průběhu tlakového namáhání. Video sloužilo pouze pro ověření funkčnosti testovaného algoritmu, proto zde není viditelný periodický průběh, jako by tomu bylo u cévy v průběhu tlakového namáhání. Tímto bylo ověřeno, že algoritmus je funkční.

6.7 Srovnání metod

Hlavní limitací metody detekce barevného markeru je umístění barevných markerů na cévu. Markery nelze umístit z boku cévy tak, aby odpovídaly reálné tloušťce aorty a postihly tak maximum z průměru aorty. Kamera se stativem by je takto nezachytila. Proto musí být markery umístěny tak, aby je algoritmus dokázal detekovat. Nikdy tak nevystihneme plný průměr aorty. Další nevýhodou je měření tloušťky aorty v jednom diskrétním místě. Nemáme tak informaci, jak se mění tloušťka jinde na aortě. Dalším faktorem je odstín modré barvy a velikost markeru, ten nesmí být moc velký, protože by došlo k chybné detekci. Výhodou této metody je nepotřebné předzpracování obrazu.

Oproti metodě detekce barvy je metoda detekce kostry aorty přesná ve výpočtu tloušťky aorty. Algoritmus vypočítá střed cévy pomocí hranice objektu a vynásobením dvěma jsme schopni zjistit přesně tloušťku aorty. Problém nastává, pokud jsou na aortě viditelné odlesky světla, které degradují kvalitu detekce a následně výpočet její tloušťky. Takový problém je vyřešen předzpracováním obrazu. Předzpracované videa dosahují lepších výsledků než nativní videa. Nevýhodou této metody je delší výpočetní náročnost než v případě metody detekce barevného markeru, která ale lze snížit podvzorkováním obrazu.

7 Modelování dynamiky cévního systému – analýza dat

Parametry, které byly vyhodnoceny v rámci této diplomové práce jsou:


- plocha
- obvod
- distribuce tloušťky

Parametry plocha a obvod byly získány z binárního modelu aorty, tloušťka je vypočítána pomocí metody skeletonu aorty.


7.1 Plocha a obvod aorty

Plocha je vypočítána pomocí funkce *bwarea*, která udává výslednou plochu v pixelech. Funkce odhaduje plochu pixelů součtem oblastí každého pixelu v obrázku. Plocha jednotlivého pixelu je určena pomocí jeho sousedních pixelů. Celkem existuje 6 vzorů pomocí kterých je plocha pixelů počítána. Obvod je vyřešen funkcí *regionprops()*, popsanou v kapitole 3. Přes '*Perimeter*', který tato funkce nabízí je změřen obvod aorty. Vypočítává obvod pomocí vzdálenosti mezi každou dvojicí pixelu kolem hranice oblasti. Je tedy nutné pro každý frame binárního modelu spočítat tyto parametry a vynést je v závislosti na čase.

Na Obr. 45 je ukázka závislosti plochy aorty v průběhu tlakového namáhání. Z grafu je patrné, že průběh signálu se periodicky opakuje a zvolený úsek 10 s je dostačující. Na Obr. 46 je zobrazena závislost obvodu cévy v průběhu tlakového namáhání. Opět byl zvolen úsek 10 s pro periodicitu průběhu. U obou průběhů je zřejmé, že pokud by zůstala dynamika cévy neměnná, byl by průběh konstantní.




Obr. 45: Závislost plochy aorty v průběhu tlakového namáhání.



Obr. 46: Závislost obvodu aorty na tlakovém namáhání.

U obou průběhů je vidět plovoucí zem, která není žádoucí. Ideální průběh parametrů by měl být kolem určité hodnoty a poloha aorty s jejím těžištěm by měla být stále na jednom místě, pouze by se roztahovala a smršťovala. Působením mechanických sil tlaku kapaliny proudící v aortě se aorta pohybuje po pracovní ploše s roztažností stěny. Tento fenomén se projevuje v plovoucí zemi. Jedná se o artefakt RBM – rigid body motion (pohyb rigidního těla). Tento artefakt nedeformuje signál, pouze je přítomna plovoucí zem. Ukázka artefaktu RBM je na Obr. 47, kde jsou ukázány 3 framy videa s měnící se polohou měřeného bodu.




Obr. 47: Artefakt RBM.


7.2 Distribuce tloušťky aorty

Pomocí metody na základě měření distribuce tloušťky aorty vznikl model, ve kterém je pro každý bod kostry aorty spočtena tloušťka pro čas, který je reprezentován framy. Pro modelování dynamiky bylo zapotřebí vzít vždy pixel se stejnou pozicí na každém framu a uložit jako řádek v nové matici. Je důležité, jakou pozici pixelu zvolíme. Pro tuto práci byly zvoleny 3 pozice bodů na kostře aorty: 117, 169 a 223.

Na Obr. 48 je uveden příklad nepřesné detekce na okraji aorty. Aby tomu bylo předcházeno, byly vždy zvoleny takové pozice pixelu, které jsou přibližně uprostřed snímku.




Obr. 48: Chybná detekce kostry aorty na okraji snímku.




Obr. 49: Vyznačené body pro měření tloušťky na aortě.

Body pro měření tloušťky byly zvoleny pro všechna videa. Nemohly být zvoleny na začátku ani na konci snímku kvůli rozdělení cévy nebo přítomnosti cizího materiálu v případě jednoho z videí.


Na Obr. 50, Obr. 51 a Obr. 52 jsou uvedeny závislosti distribuce tloušťky aorty v průběhu tlakového namáhání pro 3 pozice bodu na kostře aorty. Hodnoty pixelů jsou přibližně stejné pro všechny tři body kostry aorty. Opět je zřejmé, že v případě neměnné dynamiky by byl průběh závislosti konstantní.



Obr. 50: Závislost tloušťky aorty na čase v bodě 117.




Obr. 51: Závislost tloušťky aorty na čase v bodě 169.




Obr. 52: Závislost tloušťky aorty na čase v bodě 223.

Níže jsou uvedeny histogramy rozložení poloměru tloušťky aorty v čase pro všechny body na kostře aorty. Opět je zvoleno 252 framů. Z histogramu je patrné, že jsme schopni vyhodnocovat změny tlouštěk v čase a identifikovat, která z nich má největší dynamiku. Každý histogram má svou barvu a tam, kde se barvy střídají nejvíce, je reprezentována razance dynamických změn tloušťky v průběhu času. Barevné pruhy znamenají překrývající se histogramy s rozdílnou barvou. Na Obr. 53 lze vidět, že pro konkrétní video vykazuje největší dynamiku poloměr tloušťky 57.




Obr. 53: Histogram rozložení poloměru všech tlouštěk aorty pro 252 framů – Video 8.

Na ukázkou byly uvedeny histogramy níže pro Video 4 a Video 1. Popisovaná distribuce je pro 252 framů.



Obr. 54: Histogram rozložení poloměru všech tlouštěk aorty pro 252 framů – Video 4.



Obr. 55: Histogram rozložení poloměru tloušťky aorty pro 252 framů – Video 1.

8 Signálová analýza

Účelem signálové analýzy je ověření, zda výběr místa na aortě má vliv na naměřené parametry. Předchozí kapitola je věnována výpočtu tří parametrů – plochy, obvodu a distribuce tloušťky cévy. Pro všechny tyto parametry je spočítána střední hodnota, výkon, energie, minimální a maximální hodnota. Všechny parametry jsou počítány pro všechny záznamy videí a následně vyneseny do tabulek. V Tab. 8 a Tab. 9 jsou vypočítány parametry pro plochu a obvod, Tab. 10, Tab. 11 a Tab. 12 jsou pro tloušťku ve třech různých bodech na kostře aorty.

Střední hodnota se v případě plochy pohybovala od 43 520 do 112 050 px. Aorta v případě videa 5 je zachycena v širším úseku, proto se hodnoty u videa5 velmi liší od ostatních hodnot. Minimální hodnota pro parametr plochy je 42 994 px, maximální hodnota je 114 180 px.

Použité vzorce:

$$\text{Střední hodnota:} \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (8.1)$$

$$\text{Výkon:} \quad \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T |s(t)|^2 dt \quad (8.2)$$

$$\text{Energie:} \quad \lim_{T \rightarrow \infty} \int_{-T}^T |s(t)|^2 dt \quad (8.3)$$

Tab. 8: Vypočítané parametry plochy pro všechna videa.

	Střední hodnota [px]	Minimální hodnota [px]	Maximální hodnota [px]	Výkon [px]	Energie [px]
Video1	44 109	43 544	44 572	$49\,889 \cdot 10^6$	$48\,836 \cdot 10^7$
Video2	43 889	43 482	44 472	$49\,388 \cdot 10^6$	$48\,346 \cdot 10^7$
Video3	43 520	42 994	44 994	$48\,563 \cdot 10^7$	$47\,538 \cdot 10^7$
Video4	78 170	75 336	81 933	$15\,675 \cdot 10^7$	$15\,344 \cdot 10^8$
Video5	112 050	107 352	114 180	$32\,200 \cdot 10^7$	$31\,520 \cdot 10^8$
Video6	64 402	62 390	66 559	$10\,638 \cdot 10^7$	$10\,414 \cdot 10^8$
Video7	62 117	61 744	63 441	$98\,932 \cdot 10^6$	$96\,845 \cdot 10^7$

V případě obvodu byla střední hodnota zjištěna v rozmezí od 1 135,8 do 1 616,8 px. Minimální hodnota obvodu je 1 131,5 px, maximální hodnota je 1 663,6 px.

Tab. 9: Vypočítané parametry obvodu pro všechna videa.

	Střední hodnota [px]	Minimální hodnota [px]	Maximální hodnota [px]	Výkon [px]	Energie [px]
Video1	1 150,2	1 144,8	1 154,8	$3\,392 \cdot 10^4$	$3\,320,5 \cdot 10^5$
Video2	1 505,2	1 498,4	1 517,1	$5\,809 \cdot 10^4$	$5\,686,4 \cdot 10^5$
Video3	1 135,8	1 131,5	1 141,9	$3\,308 \cdot 10^4$	$3\,238,3 \cdot 10^5$
Video4	1 616,8	1 570,5	1 663,6	$6\,703,8 \cdot 10^4$	$6\,562,4 \cdot 10^5$
Video5	1 354,3	1 343,9	1 362,5	$4\,702,6 \cdot 10^4$	$4\,603,4 \cdot 10^5$
Video6	1 223,9	1 213,6	1 234,8	$3\,840,9 \cdot 10^4$	$3\,759,9 \cdot 10^5$
Video7	1 379,9	1 376,3	1 385,7	$4\,882,1 \cdot 10^4$	$4\,779,1 \cdot 10^5$

Pro videa tlouštěk jsou si hodnoty pro všechny 3 body velmi podobné, liší se pouze minimálně. Opět v případě videa 5 jsou zaznamenány hodnoty lišící se od ostatních u důvodu širokého úseku aorty.

Tab. 10: Vypočítané parametry tloušťky v bodě 117 pro všechna videa.

	Střední hodnota [px]	Minimální hodnota [px]	Maximální hodnota [px]	Výkon [px]	Energie [px]
Video1	88,7635	86,5794	90,1998	202 030	$19,777 \cdot 10^5$
Video2	81,9956	80,0250	84,0952	172 400	$16,876 \cdot 10^5$
Video3	91,6335	90	94,3398	215 310	$21,077 \cdot 10^5$
Video4	67,8633	60,7289	73,2393	118 610	$11,611 \cdot 10^5$
Video5	214,9342	202,9877	256	$11\,860 \cdot 10^2$	$11,610 \cdot 10^6$
Video6	122,3282	61,3514	130,1384	387 970	379 780
Video7	120,1716	118,0678	120,8305	370 300	$36,248 \cdot 10^5$

Tab. 11: Vypočítané parametry tloušťky v bodě 169 pro všechna videa.

	Střední hodnota [px]	Minimální hodnota [px]	Maximální hodnota [px]	Výkon [px]	Energie [px]
Video1	88,9384	86,3713	92	202 860	$19,858 \cdot 10^5$
Video2	79,3882	78,2304	81,2158	161 620	$15,821 \cdot 10^5$

Video3	91,8981	90	94	216 550	$21,198 \cdot 10^5$
Video4	78,7797	34,9285	106,5082	178 280	$14,452 \cdot 10^5$
Video5	222,0999	213,8411	244,4995	126 580	$12,391 \cdot 10^6$
Video6	64,3022	56	108,9036	106 220	$10,398 \cdot 10^5$
Video7	114,3496	112,8716	115,4123	335 290	$32,822 \cdot 10^5$

Tab. 12: Vypočítané parametry tloušťky v bodě 223 pro všechna videa

	Střední hodnota [px]	Minimální hodnota [px]	Maximální hodnota [px]	Výkon [px]	Energie [px]
Video1	86,7670	84,3801	88,3629	193 060	$18,898 \cdot 10^5$
Video2	80,2938	79,2465	82,0244	165 310	$16,182 \cdot 10^5$
Video3	89,8772	86,0930	92	207 120	$20,275 \cdot 10^5$
Video4	73,7737	4,4721	106,3015	170 200	$16,661 \cdot 10^5$
Video5	208,1008	164,4384	228,9629	112 280	$10,991 \cdot 10^6$
Video6	75,1026	31,2410	92	150 150	$14,698 \cdot 10^5$
Video7	125,3696	124,5953	127,0118	403 010	$39,451 \cdot 10^5$

8.1.1 Vliv lokalizace na naměřené parametry

V této kapitole jsou porovnávány střední hodnoty pro parametry plocha, obvod a tloušťka ve 3 různých bodech. Všechny rozdíly hodnot mezi jednotlivými videi jsou uvedeny v tabulkách níže ve formě procent.

Největší rozdíly hodnot jsou u parametru plocha, kde záleží na šířce daného úseku aorty. Největší rozdíl je mezi videem 3 a videem 5, naopak nejmenší rozdíl plochy je mezi videem 1 a videem 2. Pro parametr obvodu vyšel nejmenší rozdíl mezi videem 1 a videem 3, největší rozdíl byl mezi videem 3 a videem 4.

Tab. 13: Rozdíly středních hodnot mezi jednotlivými záznamy pro plochu v %.

	Video1	Video2	Video3	Video4	Video5	Video6	Video7
Video1	x	0,50	1,35	77,22	154,03	46,01	40,83
Video2	0,50	x	0,85	78,11	155,30	46,74	41,53
Video3	1,35	0,85	x	79,62	157,47	47,98	42,73
Video4	77,22	78,11	79,62	x	43,34	21,38	25,84
Video5	154,03	155,30	157,47	43,34	x	73,99	80,39

Video6	46,01	46,74	47,98	21,38	73,99	x	3,68
Video7	40,83	41,53	42,73	25,84	80,39	3,68	x

Tab. 14: Rozdíly středních hodnot mezi jednotlivými záznamy pro obvod v %.

	Video1	Video2	Video3	Video4	Video5	Video6	Video7
Video1	x	30,86	1,25	40,56	17,76	6,41	19,97
Video2	30,86	x	32,52	7,41	11,14	22,98	9,08
Video3	1,25	32,52	x	42,35	19,24	7,76	21,52
Video4	40,56	7,41	42,35	x	19,38	32,10	17,17
Video5	17,76	11,14	19,24	19,38	x	10,65	1,89
Video6	6,41	22,98	7,76	32,10	10,65	x	12,74
Video7	19,97	9,08	21,52	17,17	1,89	12,74	x

Tab. 15: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku v bodě 117 v %.

	Video1	Video2	Video3	Video4	Video5	Video6	Video7
Video1	x	8,25	3,23	30,79	142,14	37,81	35,38
Video2	8,25	x	11,75	20,82	162,13	49,18	46,58
Video3	3,23	11,75	x	35,03	134,56	33,49	31,14
Video4	30,79	20,82	35,03	x	216,72	80,26	77,08
Video5	142,14	162,13	134,56	216,72	x	75,70	78,85
Video6	37,81	49,18	33,49	80,26	75,70	x	1,79
Video7	35,38	46,58	31,14	77,08	78,85	1,79	x

Tab. 16: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku v bodě 169 v %.

	Video1	Video2	Video3	Video4	Video5	Video6	Video7
Video1	x	12,03	3,33	12,89	149,72	38,31	28,57
Video2	12,03	x	15,76	0,77	179,76	23,46	44,04
Video3	3,33	15,76	x	16,65	141,68	42,92	24,43
Video4	12,89	0,77	16,65	x	181,93	22,51	45,15
Video5	149,72	179,76	141,68	181,93	x	245,40	96,77
Video6	38,31	23,46	42,92	22,51	245,40	x	77,83

Video7	28,57	44,04	24,43	45,15	96,77	77,83	x
--------	-------	-------	-------	-------	-------	-------	---

Tab. 17: Rozdíly středních hodnot mezi jednotlivými záznamy pro tloušťku v bodě v %.

	Video1	Video2	Video3	Video4	Video5	Video6	Video7
Video1	x	8,06	3,58	17,61	139,83	15,53	44,49
Video2	8,06	x	11,94	8,84	159,17	6,91	56,14
Video3	3,58	11,94	x	21,83	131,53	19,67	39,49
Video4	17,61	8,84	21,83	x	182,08	1,80	69,94
Video5	139,83	159,17	131,53	182,08	x	177,09	65,99
Video6	15,53	6,91	19,67	1,80	177,09	x	66,93
Video7	44,49	56,14	39,49	69,94	65,99	66,93	x

V Tab. 18 jsou uvedeny maximální a minimální rozdíly mezi videi pro jednotlivé parametry. Z rozdílů hodnot uvedených v tabulkách vyplývá, že výběr místa na aortě má vliv na naměřené parametry.

Tab. 18: Maximální a minimální rozdíl mezi videi pro jednotlivé parametry.

	Plocha	Obvod	Tloušťka 117	Tloušťka 169	Tloušťka 223
Maximální rozdíl	3-5	3-4	4-5	5-6	4-5
Minimální rozdíl	1-2	1-3	6-7	2-4	1-3


8.1.2 Analýza frekvence

Analýza frekvence byla provedena u parametrů plocha a obvod. Tyto signály vykazují periodický průběh. Pro výpočet frekvence je potřeba signály vyhladit. Dojde k eliminaci záškubů na signále a vyjde tak aproximovaný signál, který má hladký průběh. Pro tyto účely je použit Savitzky-Golay filtr, který aproximuje okolí bodu pomocí hladké polynominální křivky. Zde je nutné nastavit řád polynomu a velikost okenní funkce. Cílem je signál co nejvíce vyhladit, ale zároveň ho co nejméně poškodit.

Nastavené parametry Savitzky-Golay filtru:


- řád polynomu: 3
- velikost okenní funkce: 5

Tyto nastavené parametry byly u všech videí, kromě videa 4, videa 5 a videa 7 u parametru plochy. Zde byl nastaven řád polynomu na hodnotu 1, velikost okenní funkce zůstala stejná. Ukázka originálního a filtrovaného signálu je na Obr. 56.




Obr. 56: Filtrace signálu Savitzky-Golay filtrem.

Na takto filtrované signály se použije detektor maxim (viz. Obr. 57), který pomocí difference zjišťuje vzdálenost peak-peak. Pokud je tato vzdálenost stejná, jedná se o čistě periodické signály. Čím větší bude změna této vzdálenosti, tím méně jsou signály periodické. Z periody se dále vypočte frekvence a její rozptyl. Pomocí rozptylu lze zjistit, jestli se parametry mění čistě periodicky, nebo je tam prudká změna od střední hodnoty.



Obr. 57: Detektor maxim aplikovaný na filtrovaný signál.

Na Obr. 58 je uvedena závislost vzdálenosti peak-peak na čase pro parametr plochy. Všechny hodnoty až na dvě jsou v linii, takže lze tvrdit, že signál je periodický.



Obr. 58: Závislost vzdálenosti peak-peak na čase.

V Tab. 19 a Tab. 20 jsou uvedeny všechny vypočítané parametry u všech záznamů pro parametr plochy a obvodu. Pro plochu vyšel rozptyl frekvence u každého záznamu pod 10 Hz. O něco horších výsledků dosahuje obvod, kde u některých videí bylo obtížné detekovat pouze maxima signálu. Žádný ze záznamů ale nedosahuje takových hodnot, aby bylo možno tvrdit, že signál není periodický.

Tab. 19: Výpočet jednotlivých parametrů pro plochu pro každý záznam.

	Plocha			
	Střední hodnota periody [s]	Směrodatná odchylka	Střední hodnota frekvence [Hz]	Rozptyl frekvence [Hz]
Video1	0,5529	0,0153	1,8100	0,0023
Video2	0,4346	0,1380	2,5888	0,9325
Video3	0,5222	0,1136	2,4386	6,7213
Video4	0,5529	0,1978	2,5613	3,4726
Video5	0,4897	0,1405	2,2217	0,5810
Video6	0,4926	0,1437	2,7928	8,2595
Video7	0,5582	0,0883	1,7960	0,0076

Tab. 20: Výpočet jednotlivých parametrů pro obvod pro každý záznam.

	Obvod			
	Střední hodnota periody [s]	Směrodatná odchylka	Střední hodnota frekvence [Hz]	Rozptyl frekvence [Hz]
Video1	0.2860	0,1586	5.0952	11.4531
Video2	0,2398	0,1143	5,0788	5,8765
Video3	0,1606	0,0862	8,1955	16,1096
Video4	0,2011	0,1309	6,9512	14,6861
Video5	0,5557	0,1635	1,8022	0,0054
Video6	0,2145	0,1111	6,0846	11,3097
Video7	0,1818	0,0688	6,3989	7,1721

9 Statistická analýza

Účelem k provedení statistické analýzy je doložení, zda místo měření je statisticky významné pro měření míry deformace. Testovány jsou všechny tři parametry. Nejprve jsou vypočteny deskriptivní parametry – střední hodnota, medián, dolní a horní kvantil a interkvantilové rozpětí, následně jsou provedeny dvouvýběrové a vícevýběrové charakteristiky.

9.1 Použité parametry a testy

V této kapitole budou vysvětleny parametry a testy použité v této práci. Jedná se o následující parametry:

- **Střední hodnota** neboli aritmetický průměr je definován jako součet všech hodnot náhodné proměnné dělený počtem hodnot [22]. Matematický vztah pro výpočet střední hodnoty je:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (9.1)$$

- **Medián** ($x_{0,5}$) je 50% kvantil, který rozděluje datový soubor tak, že polovina hodnot je menších než medián a polovina hodnot je větších nebo rovných [22].

$$\tilde{x} = x(n+1)/2 \quad (9.2)$$

- **Dolní kvantil** ($x_{0,25}$) je 25% kvantil a rozděluje datový soubor tak, že 25 % hodnot je menších než tento kvantil a 75 % hodnot je větších nebo rovných [22].
- **Horní kvantil** ($x_{0,75}$) je 75% kvantil a rozděluje datový soubor tak, že 75 % hodnot je menších než tento kvantil a 25 % hodnot je větších, nebo rovných [22].

$$z_p = n * \frac{p}{100} + 0,5 \quad (9.3)$$

Kde n je rozsah základního souboru a p je procento hledaného kvantilu.

- **Interkvantilové rozpětí** je definované jako vzdálenost mezi horním a dolním kvantilem [22].

$$IQR = x_{0,75} - x_{0,25} \quad (9.4)$$

- **Krabicový graf** (Box plot) a jeho vysvětlení je znázorněno na Obr. 59. Odlehlá pozorování jsou označena jako izolované body, konec horního vousu představuje maximum, konec dolního vousu minimum. Horní víko krabice udává horní kvantil, dno dolní kvartil, úsečka uvnitř označuje medián. Z polohy mediánu vzhledem ke krabici lze usuzovat symetrie vnitřních 50 % dat a získat tak informace o středu a rozptýlenosti proměnné [22].



Obr. 59: Krabicový graf, upraveno podle [22].

- **QQ graf** udává informaci o normálním rozložení dat. V ideálním případě leží všechny hodnoty na přímce [22].
- **Kolmogorův-Smirnov test**, řadí se mezi neparametrické testy, ověřuje normalitu. Oboustranný test testuje nulovou hypotézu proti alternativě. Test funguje na principu výpočtu maxima absolutního rozdílu mezi empirickou CDF (spojitá distribuční funkce) a hypotetickou CDF [23].

$$D = \max (|\hat{F}(x) - G(x)|) \quad (9.5)$$

- **Leveneův test** se používá k testování, zda má více vzorků dat stejné rozptyly.

$$W = \frac{(N - k) \sum_{i=1}^k N_i (\bar{Z}_i - Z)^2}{(k - 1) \sum_{i=1}^k \sum_{j=1}^{N_i} (Z_{ij} - \bar{Z}_i)^2} \quad (9.6)$$

kde k je počet skupin

N_i je velikost vzorku i -té skupiny

$Z_{ij} = |Y_{ij} - \bar{Y}_i|$, \bar{Y}_i je průměr i -té podskupiny [24].

- **Wilcoxonův test** se řadí mezi neparametrické testy, testující shodu mediánů. Pro dva nezávislé vzorky. V Matlabu je ekvivalentním testem Mannův-Whitneyův U-test. Písmeno U značí kolikrát y předchází x v uspořádaném množství prvků [25].

$$U = W - \frac{n_x(n_x + 1)}{2} \quad (9.7)$$

- **Kruskal-Wallisův test** neparametrickou verzí klasického testu ANOVA. Porovnává střední hodnoty dat pro zjištění, zda vzorky pocházejí ze stejné populace. Vyhledává pozice seřazením dat od nejmenších po největší pomocí číselného indexu tohoto uspořádání. F statistika použitá u klasického testu ANOVA je nahrazena statistikou chí-kvadrát a p -hodnotou, měřící význam statistiky chí-kvadrát [26].
- **Dunn metoda** je post-hoc analýza pro Kruskalův-Wallisův test. Používá se pro mnohonásobné porovnávání v případě zamítnutí nulové hypotézy. Porovnává která dvojice výběrů se od sebe statisticky významně liší [27].

9.2 Statistická analýza pro parametr plochy

V této kapitole je zahrnut výpočet deskriptivních parametrů, dále grafická prezentace dat (krabicový graf a QQ graf), dvouvýběrové a vícevýběrové charakteristiky.

9.2.1 Výpočet deskriptivních parametrů

V Tab. 21 jsou zaznamenány deskriptivní parametry pro všechna videa. Průměrně se hodnoty pohybují v rozmezí od 43 520 do 112 050.


Tab. 21: Deskriptivní statistické údaje pro parametr plochy.

	Střední hodnota [px]	Medián [px]	Dolní kvartil [px]	Horní kvartil [px]	Interkvartilové rozpětí [px]
Video1	44 109	44 114	43 959	44 286	327
Video2	43 889	43 870	43 733	44 061	328
Video3	43 520	43 496	43 245	43 717	472
Video4	78 170	77 972	77 301	78 996	1 695
Video5	112 050	112 390	111 350	113 080	1 730
Video6	64 402	64 393	63 723	65 028	1 305
Video7	62 117	62 038	61 936	62 231	295


9.2.2 Dvouvýběrová charakteristika

Nejprve je potřeba ověřit předpoklady testů. U všech dat je nutno ověřit, zda jsou data z normálního rozložení. Nejprve budou data zhodnocena grafickou reprezentací, následně bude normalita ověřena pomocí testu.

Na Obr. 60 a Obr. 61 jsou zobrazeny krabicové grafy pro všechna videa. U videí 3, 4, 5 a 7 jsou viditelná odlehlá pozorování. Vzhledem k povaze lze soudit, že chyby nevznikly při měření, a proto nebudou pro další analýzu odstraněny.




Obr. 60: Krabicový graf pro videa 1, 2 a 3.




Obr. 61: Krabicový graf pro videa 4, 5, 6 a 7.

Další grafická reprezentace dat je QQ graf. Na Obr. 62 a Obr. 63 jsou zobrazeny distribuce pro všechna videa. Na základě grafických reprezentací lze předpokládat, že data nebudou pocházet z normálního rozdělení. Pro konečné rozhodnutí o normalitě dat bude použit test normality.



Obr. 62: Q-Q graf hodnot pro video 1, 2 a 4.



Obr. 63: Q-Q graf hodnot pro video 4, 5, 6 a 7.

Pro ověření normality byl použit Kolmogorův-Smirnov test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza:

H_0 : Hodnoty parametrů plochy pocházejí z normálního rozložení

H_A : $\neg H_0$

Tab. 22: Ověření normality (Kolmogorův-Smirnov test).

	p-hodnota	Rozhodnutí
Video1	$\ll 0,001$	zamítnutí H_0

Video2	$\ll 0,001$	zamítnutí H_0
Video4	$\ll 0,001$	zamítnutí H_0
Video5	$\ll 0,001$	zamítnutí H_0
Video6	$\ll 0,001$	zamítnutí H_0
Video7	$\ll 0,001$	zamítnutí H_0
Video8	$\ll 0,001$	zamítnutí H_0

Na hladině významnosti 5 % je zamítnut předpoklad normality u všech zkoumaných dat (p-hodnoty $\ll 0,001$, Kolmogorův-Smirnov test). Výsledky jsou uvedeny v Tab. 22.

Pro ověření homoskedasticity byl zvolen Levenův test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza.

H_0 : Hodnoty parametru plochy má stejný rozptyl

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnuta nulová hypotéza ve prospěch alternativní, tedy data nemají stejný rozptyl, jsou heteroskedastická. Tento rozdíl lze označit za statisticky významný. To platí pro všechna testovaná videa s výjimkou testovaného souboru videí 1-2, 2-7 a 4-5. Tyto 3 skupiny porovnaných videí jsou homoskedastická.

Jelikož je zamítnut předpoklad normality, nelze pracovat se středními hodnotami, ale s mediány. Pro test mediánů byl použit Wilcoxonův test. Je definována nulová a alternativní hypotéza:

H_0 : Mediány hodnot pro parametr plochy se rovnají

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnuta nulová hypotéza ve prospěch alternativní, tedy mediány hodnot pixelů plochy si nejsou rovny (p-hodnota $\ll 0,001$, Wilcoxonův test).

Výsledky Levenova a Wilcoxonova testu včetně rozhodnutí jsou uvedeny v Tab. 23.

Tab. 23: Dvouvýběrové charakteristiky pro všechny kombinace videí.

Testovaná videa	Levenův test p-hodnota	rozhodnutí	Wilcoxonův test p-hodnota	rozhodnutí
1-2	0,569	nezamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-3	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-7	0,2379	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0

2-3	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-7	0,1010	nezamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-7	0,0027	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-5	0,911	nezamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
6-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0

9.2.3 Vícevýběrová charakteristika pro parametr plochy

Pro vícevýběrové charakteristiky je z důvodu zamítnuté normality dat použit Leveneův test pro ověření shody rozptylů. Na hladině 5 % je definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % je zamítnut předpoklad o shodě rozptylů (p-hodnota $\ll 0,001$, Levenův test).

Z důvodu zamítnuté normality je nutné pracovat s mediány pixelů plochy. Pro ověření byl použit Kruskal-Wallisův test. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Tab. 24: Kruskal-Wallisův test pro parametr plochy.

	Součet čtverců	Stupně volnosti	Průměr čtverců	Chí-kvadrát	p-hodnota
Skupinový faktor	$4,33 \cdot 10^8$	6	$7,22 \cdot 10^7$	$1,67 \cdot 10^3$	$\ll 0,001$

Reziduální faktor	$2,42 \cdot 10^7$	1757	$1,38 \cdot 10^4$	-	-
Celkem	$4,57 \cdot 10^8$	1763	-	-	-

Na hladině významnosti 5 % je zamítnuta nulová hypotéza, alespoň u jedné skupiny se mediány nerovnají. Výsledky Kruskal-Wallisova testu jsou uvedeny v Tab. 24.

Jelikož je zamítnuta nulová hypotéza, je pro další analýzu provedena post-hoc analýza metodou Dunnové. Je potřeba zjistit, který medián videa se statisticky významně liší od ostatních.

Tab. 25: Post-hoc Dunn analýza.

Testovaná videa	95% intervalový odhad	Rozdíl mediánů	p-hodnota
1-2	(0,016; 0,284)	0,1497	$\ll 0,001$
1-3	(0,234; 0,502)	0,3678	$\ll 0,001$
1-4	(-0,969; -0,702)	-0,8355	$\ll 0,001$
1-5	(-1,221; -0,954)	-1,0875	$\ll 0,001$
1-6	(-0,716; -0,449)	-0,5826	$\ll 0,001$
1-7	(-0,466; -0,199)	-0,3324	$\ll 0,001$
2-3	(0,084; 0,352)	0,2181	$\ll 0,001$
2-4	(-1,119; -0,851)	-0,9852	$\ll 0,001$
2-5	(-1,371; -1,103)	-1,2372	$\ll 0,001$
2-6	(-0,866; -0,599)	-0,7323	$\ll 0,001$
2-7	(-0,616; -0,348)	-0,4821	$\ll 0,001$
3-4	(-1,337; -1,069)	-1,2033	$\ll 0,001$
3-5	(-1,589; -1,322)	-1,4553	$\ll 0,001$
3-6	(-1,084; -0,817)	-0,9504	$\ll 0,001$
3-7	(-0,834; -0,566)	-0,7002	$\ll 0,001$
4-5	(-0,386; -0,118)	-0,2520	$\ll 0,001$
4-6	(0,119; 0,387)	0,2529	$\ll 0,001$
4-7	(0,369; 0,637)	0,5031	$\ll 0,001$
5-6	(0,371; 0,639)	0,5049	$\ll 0,001$
5-7	(0,621; 0,889)	0,7551	$\ll 0,001$
6-7	(0,116; 0,384)	0,2501	$\ll 0,001$

Jelikož u všech testovaných videí vyšla p-hodnota $\ll 0,001$ lze konstatovat, že rozdíl mediánů je statisticky významný. Výsledky Dunn analýzy jsou uvedeny v Tab. 25.

9.3 Statistická analýza pro parametr obvodu

Nejprve jsou vypočítány deskriptivní parametry, dále je provedena grafická prezentace dat (krabicový graf a QQ graf), dvouvýběrové a vícevýběrové charakteristiky.

9.3.1 Výpočet deskriptivních parametrů


V Tab. 26 jsou zaznamenány deskriptivní parametry pro všechny záznamy. Střední hodnoty pixelů pro obvod se pohybují od 1 150,2 do 1 616,8.

Tab. 26: Deskriptivní statistické údaje pro parametr obvodu.


	Střední hodnota [px]	Medián [px]	Dolní kvartil [px]	Horní kvartil [px]	Interkvartilové rozpětí [px]
Video1	1 150,2	1 150,3	1 148,7	1 151,5	2,8
Video2	1 505,2	1504,7	1 502,5	1 507,5	5
Video3	1 135,8	1 135,7	1 134,5	1 136,8	2,3
Video4	1 616,8	1 606,2	1 593,9	1 640,0	46,1
Video5	1 354,3	1 354,2	1 349,9	1 359,1	9,2
Video6	1 223,9	1 223,8	1 221,7	1 226,5	4,8
Video7	1 379,9	1 379,8	1 379,1	1 380,5	1,4

9.3.2 Dvouvýběrová charakteristika


Nejprve je zhodnocena grafická prezentace dat. Křabicové grafy pro všechna videa jsou uvedeny na Obr. 64, Obr. 65 a Obr. 66. Videa jsou rozdělena do skupin podle počtu pixelů obvodu. Videa 2, 3, 6 a 7 obsahují odlehlá pozorování. Ani v tomto případě nebyla odlehlá pozorování odstraněna.



Obr. 64: Krabicový graf pro videa 1 a 3.




Obr. 65: Krabicový graf pro videa 2 a 4.




Obr. 66: Krabicový graf pro videa 5, 6 a 7.

QQ graf demonstruje Obr. 67 a Obr. 68. Videa 1, 2, 3 a 6 nasvědčují tomu, že může být splněn předpoklad normality. Normalita je následně ověřena testem.



Obr. 67: QQ graf hodnot pro videa 1, 2 a 3.



Obr. 68: QQ graf hodnot pro videa 4, 5, 6 a 7.

Pro ověření normality byl použit Kolmogorův-Smirnov test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza:

H_0 : Hodnoty parametru obvodu pocházejí z normálního rozložení

H_A : $\neg H_0$

Tab. 27: Ověření normality (Kolmogorův-Smirnov test).

	p-hodnota	Rozhodnutí
Video1	$\ll 0,001$	zamítnutí H_0
Video2	$\ll 0,001$	zamítnutí H_0
Video4	$\ll 0,001$	zamítnutí H_0
Video5	$\ll 0,001$	zamítnutí H_0
Video6	$\ll 0,001$	zamítnutí H_0
Video7	$\ll 0,001$	zamítnutí H_0
Video8	$\ll 0,001$	zamítnutí H_0

Na hladině významnosti 5 % je zamítnut předpoklad normality u všech zkoumaných dat (p-hodnoty $\ll 0,001$, Kolmogorův-Smirnov test). Výsledky jsou uvedeny v Tab. 27.

Pro ověření homoskedasticity byl zvolen Levenův test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza.

H_0 : Hodnoty parametru obvodu mají stejný rozptyl

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnuta nulová hypotéza ve prospěch alternativní, tedy data nemají stejný rozptyl, jsou heteroskedasticitní. Tento rozdíl lze označit za statisticky významný. To platí pro všechna testovaná videa s výjimkou testovaného souboru videí 2-6. Tato skupina porovnávaných videí je homoskedasticitní.

Tab. 28: Dvouvýběrové charakteristiky pro všechny kombinace videí.

Testovaná videa	Levenův test p-hodnota	rozhodnutí	Wilcoxonův test p-hodnota	rozhodnutí
1-2	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-3	0,0475	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-3	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-6	0,8837	nezamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
6-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0

9.3.3 Vícevýběrová charakteristika pro parameter obvodu

Z důvodu zamítnuté normality dat je použit Levenův test pro ověření shody rozptylů. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % je zamítnut předpoklad o shodě rozptylů (p-hodnota $\ll 0,001$, Levenův test).

Stejně jako u parametru plochy je z důvodu zamítnuté normality použit Kruskal-Wallisův test. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % je zamítnut nulovou hypotézu, alespoň u jedné skupiny se mediány nerovnají. Výsledky Kruskal-Wallisova testu jsou uvedeny v Tab. 29. Pro další analýzu je provedena post-hoc analýza metodou Dunnové.

Tab. 29: Kruskal-Wallisův test pro parametr obvodu.

	Součet čtverců	Stupně volnosti	Průměr čtverců	Chí-kvadrát	p-hodnota
Skupinový faktor	$4,48 \cdot 10^8$	6	$7,46 \cdot 10^7$	$1,73 \cdot 10^3$	$\ll 0,001$
Reziduální faktor	$9,33 \cdot 10^7$	1757	$5,31 \cdot 10^3$	-	-
Celkem	$4,57 \cdot 10^8$	1763	-	-	-

Jelikož je zamítnuta nulová hypotéza, je pro další analýzu provedena post-hoc analýza metodou Dunnové. Je potřeba zjistit, který medián videa se statisticky významně liší od ostatních.

Tab. 30: Post-hoc Dunn analýza.

Testovaná videa	95% intervalový odhad	Rozdíl mediánů	p-hodnota
1-2	(-1,142; -0,874)	-1,008	$\ll 0,001$
1-3	(0,118; 0,386)	0,252	$\ll 0,001$
1-4	(-1,394; -1,126)	-1,260	$\ll 0,001$
1-5	(-0,638; -0,370)	-0,504	$\ll 0,001$
1-6	(-0,386; -0,118)	-0,252	$\ll 0,001$
1-7	(-0,890; -0,622)	-0,756	$\ll 0,001$
2-3	(1,126; 1,394)	1,260	$\ll 0,001$
2-4	(-0,386; -0,118)	-0,252	$\ll 0,001$

2-5	(0,370; 0,638)	0,504	$\ll 0,001$
2-6	(0,622; 0,890)	0,756	$\ll 0,001$
2-7	(0,118; 0,386)	0,252	$\ll 0,001$
3-4	(-1,646; -1,378)	-1,512	$\ll 0,001$
3-5	(-0,890; -0,622)	-0,756	$\ll 0,001$
3-6	(-0,638; -0,370)	-0,504	$\ll 0,001$
3-7	(-1,142; -0,874)	-1,008	$\ll 0,001$
4-5	(0,622; 0,890)	0,756	$\ll 0,001$
4-6	(0,874; 1,142)	1,008	$\ll 0,001$
4-7	(0,370; 0,638)	0,504	$\ll 0,001$
5-6	(0,118; 0,386)	0,252	$\ll 0,001$
5-7	(-0,386; -0,118)	-0,252	$\ll 0,001$
6-7	(-0,638; -0,370)	-0,504	$\ll 0,001$

Jelikož u všech testovaných videí vyšla p-hodnota $\ll 0,001$ lze konstatovat, že rozdíl mediánů je statisticky významný. Výsledky post-hoc analýzy jsou uvedeny v Tab. 30.

9.4 Statistická analýza pro parametr tloušťky

Měření tloušťky bylo provedeno na 3 vybraných bodech kostry aorty. Statistická analýza bude provedena pro jeden bod kostry aorty, neboť výsledky jsou velmi podobné.

9.4.1 Výpočet deskriptivních parametrů

Deskriptivní parametry byly vypočítány pro všechny 3 body kostry aorty. Z tabulek níže je patrné, že hodnoty pro všechny 3 body jsou si velmi podobné.

Tab. 31: Deskriptivní statistické údaje pro parametr tloušťky v bodě 117.

	Střední hodnota [px]	Medián [px]	Dolní kvartil [px]	Horní kvartil [px]	Interkvartilové rozpětí [px]
Video1	88,7635	88,5664	88,3629	88,9605	0,5977
Video2	81,9956	82,0244	82	82,0975	0,0975
Video3	91,6335	92	90,2773	92	1,7227
Video4	67,8633	69,9714	62,0322	72,1110	10,0788
Video5	214,9342	213,2463	210,6086	217,3292	6,7206
Video6	122,3282	128	126,0159	128,0156	1,9998

Video7	120,1716	120,3329	119,6161	120,8305	1,2144
--------	----------	----------	----------	----------	--------

Tab. 32: Deskriptivní statistické údaje pro parametr tloušťky v bodě 169.

	Střední hodnota [px]	Medián [px]	Dolní kvartil [px]	Horní kvartil [px]	Interkvartilové rozpětí [px]
Video1	88,9384	89,1067	88	90	2
Video2	79,3882	78,9177	78,6384	80,2247	1,5863
Video3	91,8981	92,1954	92	92,1954	0,1954
Video4	78,7797	96,6023	44,9444	100,1798	55,2354
Video5	222,0999	221,8873	216,5918	226,3184	9,7266
Video6	64,3022	63,9062	62,0322	65,7875	3,7553
Video7	114,3496	114,1403	114,1403	114,8564	0,7162


Tab. 33: Deskriptivní statistické údaje pro parametr tloušťky v bodě 223.

	Střední hodnota [px]	Medián [px]	Dolní kvartil [px]	Horní kvartil [px]	Interkvartilové rozpětí [px]
Video1	86,7670	86,2090	86	88	2
Video2	80,2938	80	80	80	0
Video3	89,8772	90	90	90	0
Video4	73,7737	90,0888	82,3043	93,7337	11,4294
Video5	208,1008	219,4630	202,8694	224,1830	21,3135
Video6	75,1026	81,5158	79,6482	82,8010	3,1517
Video7	125,3696	125,2966	125,2517	125,6025	0,3508


9.4.2 Dvouvýběrová charakteristika

Dále bude zpracováván pouze jeden bod na kostře aorty. Nejprve je potřeba ověřit předpoklady testů, zda jsou data z normálního rozložení. Data budou nejprve zhodnocena grafickou reprezentací, následně bude ověřena normalita pomocí testu.

Na Obr. 69 a Obr. 70 jsou zobrazeny krabicové grafy pro všechna videa. Video 5 má jiný rozsah hodnot než zbývající videa, proto bylo zobrazeno zvlášť. U videí 1, 2, 5 a 6 jsou viditelná odlehlá pozorování, která nebudou odstraněna.




Obr. 69: Krabicový graf pro videa 1, 2, 3, 4, 6 a 7.




Obr. 70: Krabicový graf pro video 5.

QQ grafy na Obr. 71 a Obr. 72 zobrazují distribuci tloušťky aorty pro všechna videa. Na základě těchto grafů lze předpokládat, že data nebudou pocházet z normálního rozdělení. Pro konečné rozhodnutí o normalitě dat bude použit test normality.



Obr. 71: QQ graf hodnot pro videa 1, 2 a 3.



Obr. 72: QQ graf hodnot pro videa 4, 5, 6 a 7.

Pro ověření normality byl použit Kolmogorův-Smirnov test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza:

H_0 : Hodnoty parametru tloušťky pocházejí z normálního rozložení

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnut předpoklad normality u všech zkoumaných dat (p-hodnoty $\ll 0,001$, Kolmogorův-Smirnov test). Výsledky jsou uvedeny v Tab. 34.

Tab. 34: Ověření normality (Kolmogorův-Smirnov test).

	p-hodnota	Rozhodnutí
Video1	$\ll 0,001$	zamítnutí H_0
Video2	$\ll 0,001$	zamítnutí H_0
Video4	$\ll 0,001$	zamítnutí H_0
Video5	$\ll 0,001$	zamítnutí H_0
Video6	$\ll 0,001$	zamítnutí H_0
Video7	$\ll 0,001$	zamítnutí H_0
Video8	$\ll 0,001$	zamítnutí H_0

Pro ověření homoskedasticity byl použit Levenův test. Na hladině významnosti 5 % byla definována nulová a alternativní hypotéza.

H_0 : Hodnoty parametru tloušťky mají stejný rozptyl

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnuta nulová hypotéza ve prospěch alternativní, tedy žádná data nemají stejný rozptyl, jsou heteroskedastické (p-hodnota všech testovaných videí $\ll 0,001$). Tento rozdíl lze označit za statisticky významný. To platí pro všechna testovaná videa s výjimkou testovaného souboru videí 1-7, kde vyšla p-hodnota 0,5367. Tato skupina porovnávaných videí je homoskedastická.

Jelikož je zamítnut předpoklad normality, nelze pracovat se středními hodnotami, ale s mediány. Pro test mediánů byl použit Wilcoxonův test. Je definována nulová a alternativní hypotéza:

H_0 : Mediány parametru tloušťky se rovnají

H_A : $\neg H_0$

Na hladině významnosti 5 % je zamítnuta nulová hypotéza ve prospěch alternativní, tedy mediány hodnot pixelů plochy si nejsou rovny (p-hodnota $\ll 0,001$, Wilcoxonův test).

Výsledky Levenova a Wilcoxonova testu včetně rozhodnutí jsou uvedeny v Tab. 35.

Tab. 35: Dvouvýběrové charakteristiky pro všechny kombinace videí.

Testovaná videa	Levenův test p-hodnota	rozhodnutí	Wilcoxonův test p-hodnota	rozhodnutí
1-2	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-3	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
1-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0

1-7	0,5367	nezamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-3	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
2-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-4	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
3-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-5	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
4-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-6	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
5-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0
6-7	$\ll 0,001$	zamítnutí H_0	$\ll 0,001$	zamítnutí H_0

9.4.3 Vícevýběrová charakteristika pro parameter tloušťky

Z důvodu zamítnuté normality dat použit Levenův test pro ověření shody rozptylů. Na hladině 5 % je definována nulová a alternativní hypotéza:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_7^2$$

$$H_A: \neg H_0$$

Na hladině významnosti 5 % je zamítnut předpoklad o shodě rozptylů (p-hodnota $\ll 0,001$, Levenův test).

Z důvodu zamítnuté normality je nutné pracovat s mediány pixelů plochy. Pro ověření byl použit Kruskal-Wallisův test. Na hladině významnosti 5 % je definována nulová a alternativní hypotéza:

$$H_0: x_{0,5_1} = x_{0,5_2} = \dots = x_{0,5_7}$$

$$H_A: \neg H_0$$

Tab. 36: Kruskal-Wallisův test pro parametr tloušťky.

	Součet čtverců	Stupně volnosti	Průměr čtverců	Chí-kvadrát	p-hodnota
Skupinový faktor	$4,29 \cdot 10^8$	6	$7,16 \cdot 10^7$	$1,66 \cdot 10^3$	$\ll 0,001$
Reziduální faktor	$2,74 \cdot 10^7$	1757	$1,56 \cdot 10^4$	-	-
Celkem	$4,57 \cdot 10^8$	1763	-	-	-

Na hladině významnosti 5 % je zamítnuta nulová hypotéza, alespoň u jedné skupiny se mediány nerovnájí. Výsledky Kruskal-Wallisova testu jsou uvedeny v Tab. 36. Pro další analýzu je provedena post-hoc analýza metodou Dunnové.

Tab. 37: Post-hoc Dunn analýza.

Testovaná videa	95% intervalový odhad	Rozdíl mediánů	p-hodnota
1-2	(0,129; 0,397)	0,263	$\ll 0,001$
1-3	(-0,376; -0,109)	-0,243	$\ll 0,001$
1-4	(0,389; 0,656)	0,523	$\ll 0,001$
1-5	(-1,122; -0,855)	-0,988	$\ll 0,001$
1-6	(-0,787; -0,519)	-0,653	$\ll 0,001$
1-7	(-0,661; -0,394)	-0,527	$\ll 0,001$
2-3	(-0,639; -0,372)	-0,505	$\ll 0,001$
2-4	(0,126; 0,394)	0,260	$\ll 0,001$
2-5	(-1,385; -1,117)	-1,251	$\ll 0,001$
2-6	(-1,050; -0,782)	-0,916	$\ll 0,001$
2-7	(-0,924; -0,656)	-0,790	$\ll 0,001$
3-4	(0,631; 0,899)	0,765	$\ll 0,001$
3-5	(-0,880; -0,612)	-0,746	$\ll 0,001$
3-6	(-0,544; -0,277)	-0,411	$\ll 0,001$
3-7	(-0,419; -0,151)	-0,285	$\ll 0,001$
4-5	(-1,645; -1,377)	-1,511	$\ll 0,001$
4-6	(-1,309; -1,042)	-1,176	$\ll 0,001$

4-7	(-1,184; -0,916)	-1,050	$\ll 0,001$
5-6	(0,202; 0,469)	0,335	$\ll 0,001$
5-7	(0,327; 0,595)	0,461	$\ll 0,001$
6-7	(-0,008; 0,256)	0,126	$\ll 0,001$

Jelikož u všech testovaných videí vyšla p-hodnota $\ll 0,001$ lze konstatovat, že rozdíl mediánů je statisticky významný. Výsledky post-hoc analýzy jsou uvedeny v Tab. 37.

9.5 Zhodnocení

Úkolem statistické analýzy bylo zjistit, zda je významná lokalizace konkrétní části aorty pro modelování odezvy sledovaných parametrů – plocha, obvod a tloušťka. Nejprve bylo potřeba ověřit normalitu dat, která se u všech parametrů zamítla. Proto byly v dalších analýzách srovnávány mediány. U všech zkoumaných parametrů vyšla p-hodnota $\ll 0,001$, zamítá se nulová hypotéza ve prospěch alternativní, tedy alespoň u jedné skupiny videí se mediány nerovnají a rozdíl mediánů je statisticky významný. Lze tedy konstatovat, že lokalizace části aorty pro modelování plochy, obvodu a tloušťky je statisticky významná a střední hodnota, reprezentována mediány, je na základě testů signifikantně významně odlišná mezi jednotlivými modely části aorty.

Závěr

Tato diplomová práce se zabývá analýzou dynamických záznamů tlakového namáhání umělého cévního systému.

Cílem této práce je návrh algoritmu pro detekci geometrických parametrů z video signálu a modelování dynamiky cévního systému v průběhu tlakového namáhání. V této práci je také řešeno porovnání efektivity předzpracování obrazu pro zlepšení výsledků detekce a následné testování navrženého algoritmu na reálných datech.

Sadu testovacích dat tvoří 7 videí, natočených z různých míst aorty. Jedním z úkolů této práce bylo ověření, zda lokalizace na aortě má vliv na naměřené parametry. Videá byla rozdělena na framy a zkrácena na 10 sekund záznamu, což je pro tuto práci dostačující.

Pro účely předzpracování videí bylo použito podvzorkování obrazu a mediánová filtrace. Podvzorkování obrazu je řešeno především kvůli snížení výpočetní náročnosti, mediánová filtrace kvůli odleskům světla na aortě.

V této práci byly aplikovány 2 metody. Metoda detekce barevného spektra je brána jako protiváha a alternativní metoda použitelná v dalším výzkumu. Mnohem lepších výsledků dosahuje metoda distribuce tloušťky aorty. Nejprve byl vytvořen model aorty, potřebný k získání dalších parametrů testovaných v této práci, a následně proběhla skeletonizace, která slouží k výpočtu distribuce tloušťky aorty. Dále proběhlo testování navrženého algoritmu na reálných datech. Předzpracované videa dosahují mnohem lepších výsledků než nativní data.

V další fázi byla modelována dynamika cévního systému. Byly vyhodnocovány tři parametry – plocha, obvod a distribuce tloušťky. Parametry plochy a obvodu byly získány z binárního modelu aorty, tloušťka je vypočítána pomocí metody skeletonu aorty. Z průběhů je zřejmé, že pokud by byla dynamika neměnná, průběh by byl konstantní. Zde se vyskytuje artefakt RBM, který je způsoben posunem modelu aorty po pracovní ploše v průběhu tlakového namáhání.

Na závěr proběhla signálová a statistická analýza. Účelem signálové analýzy je ověření, zda výběr místa na aortě má vliv na naměřené parametry. Součástí signálové analýzy je analýza frekvence, kdy byl zjišťován rozptyl frekvence a směrodatná odchylka periody za účelem zjištění, zda se parametry mění čistě periodicky nebo je přítomna prudká změna od střední hodnoty. Žádný ze záznamů nedosahoval takových hodnot, aby bylo možné tvrdit, že signál není periodický. Účelem provedení statistické analýzy je doložení, zda místo měření je statisticky významné pro měření míry deformace. Po zjištění normality dat a provedení odpovídajících testů statistické analýzy lze konstatovat, že lokalizace části aorty pro modelování plochy, obvodu a tloušťky aorty je statisticky významná.

Návrh a implementace algoritmu jsem prováděla v software MATLAB R2018b.

Použitá literatura

- [1] HOFRIČTER, Jiří. *Tvorba a zpracování digitálního videa* [online]. Ostrava, 2010 [cit. 2019-04-03]. Dostupné z: <http://hdl.handle.net/10084/78955>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.] [BERÁNEK, Petr. *Digitální video v praxi: [podrobný průvodce]*. 2., zcela přeprac. vyd. Praha: Mobil Media, 2003. ISBN 80-865-9334-7.
- [2] BERÁNEK, Petr. *Digitální video v praxi: [podrobný průvodce]*. 2., zcela přeprac. vyd. Praha: Mobil Media, 2003. ISBN 80-865-9334-7.
- [3] Digitalizace rastrového obrazu. *Grafika* [online]. [cit. 2019-04-04]. Dostupné z: <https://sites.google.com/site/xgrafika/digitalizace-rastroveho-obrazu#TOC-Kvantov-n->
- [4] VILÍM, Tomáš. *Detekce pohybu z video záznamu* [online]. Ostrava, 2016 [cit. 2019-04-04]. Dostupné z: <http://hdl.handle.net/10084/116260>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.]
- [5] MYSLÍN, Josef. *Digitální video v praxi: a jeho zpracování v prostředí Pinnacle Studio*. Kralice na Hané: Computer Media, 2005. ISBN 80-866-8642-6.
- [6] KONVIČKOVÁ, Svatava a Jaroslav VALENTA. *Biomechanika srdečně cévního systému člověka*. Vyd. 2. Praha: Česká technika - nakladatelství ČVUT, 1997. ISBN 80-010-3425-9.
- [7] Aortic Aneurysm. UAB MEDICINE [online]. [cit. 2019-09-03]. Dostupné z: <https://www.uabmedicine.org/patient-care/conditions/aneurysm>
- [8] Ateroskleróza. Krenizdravo [online]. 2019 [cit. 2019-09-05]. Dostupné z: <https://www.krenizdravo.rtl.hr/zdravlje/bolesti-zdravlje/ateroskleróza>
- [9] YILMAZ, Alper, Omar JAVED a Mubarak SHAH. Object tracking. *ACM Computing Surveys*. 2006, **38**(4), 13-es. DOI: 10.1145/1177352.1177355. ISSN 03600300. Dostupné také z: <http://portal.acm.org/citation.cfm?doid=1177352.1177355>
- [10] SOMKANTHA, K, N THEERA-UMPON a S AUEPHANWIRIYAKUL. Boundary Detection in Medical Images Using Edge Following Algorithm Based on Intensity Gradient and Texture Gradient Features. *IEEE Transactions on Biomedical Engineering*. 2011, **58**(3), 567-573. DOI: 10.1109/TBME.2010.2091129. ISSN 0018-9294. Dostupné také z: <http://ieeexplore.ieee.org/document/5623332/>
- [11] SRIVASTAV, Neha, Shubh L. AGRWAL, Sandeep K. GUPTA, Saurabh R. SRIVASTAVA, Blessy CHACKO a Hemant SHARMA. Hybrid object detection using improved three frame differencing and background subtraction. *IEEE*, 2017, 2017, , 613-617. DOI: 10.1109/CONFLUENCE.2017.7943225. ISBN 978-1-5090-3519-9.

- [12] SEKI, Makito; FUJIWARA, Hideto; SUMI, Kazuhiko. A robust background subtraction method for changing background. In: *Proceedings Fifth IEEE Workshop on Applications of Computer Vision*. IEEE, 2000. p. 207-213.
- [13] YANG, Mingyang. A moving objects detection algorithm in video sequence. In: *2014 International Conference on Audio, Language and Image Processing*. IEEE, 2014. p. 410-413.
- [14] KALE, Kiran, Sushant PAWAR a Pravin DHULEKAR. Moving object tracking using optical flow and motion vector estimation. 2015 4th International Conference on Reliability, Infocom Technologies and Optimization (ICRITO) (Trends and Future Directions). IEEE, 2015, 2015, , 1-6. DOI: 10.1109/ICRITO.2015.7359323. ISBN 978-1-4673-7231-2
- [15]] FOGGIA, Pasquale, Alessia SAGGESE a Mario VENTO. Real-Time Fire Detection for Video-Surveillance Applications Using a Combination of Experts Based on Color, Shape, and Motion. *IEEE Transactions on Circuits and Systems for Video Technology*. 2015, **25**(9), 1545-1556. DOI: 10.1109/TCSVT.2015.2392531. ISSN 1051-8215.
- [16] ABDELALI, Hamd Ait, Fedwa ESSANNOUNI, Leila ESSANNOUNI a Driss ABOUTAJDINE. Algorithm for moving object detection and tracking in video sequence using color feature. *2014 Second World Conference on Complex Systems (WCCS)*. IEEE, 2014, 2014, , 690-693. DOI: 10.1109/ICoCS.2014.7060999. ISBN 978-1-4799-4647-1.
- [17] TOUATI, Julien, Marco BOLOGNA, Adeline SCHWEIN, Francesco MIGLIAVACCA a Marc GARBEY. A robust construction algorithm of the centerline skeleton for complex aortic vascular structure using computational fluid dynamics. *Computers in Biology and Medicine*. 2017, **86**, 6-17. DOI: 10.1016/j.compbiomed.2017.04.017. ISSN 00104825. Dostupné také z: <https://linkinghub.elsevier.com/retrieve/pii/S0010482517301142>
- [18] Regionprops. *MathWorks* [online]. Dostupné z: <https://www.mathworks.com/help/images/ref/regionprops.html>
- [19] Imgradient. *MathWorks* [online]. Dostupné z: https://www.mathworks.com/help/images/ref/imgradient.html?searchHighlight=imgradient&s_tid=doc_srchtile
- [20] Gradient. *MathWorks* [online]. Dostupné z: https://www.mathworks.com/help/matlab/ref/gradient.html?searchHighlight=gradient&s_tid=doc_srchtile
- [21] *Popis objektů v obraze*. Brno, 2011. Diplomová práce. Vysoké učení technické v Brně.
- [22] LITSCHMANNOVÁ, Martina. Úvod do statistiky [online]. 2011 [cit. 2020-04-10]. Dostupné z: <http://mi21.vsb.cz/modul/uvod-do-statistiky>
- [23] Kstest. *MathWorks* [online]. [cit. 2020-04-10]. Dostupné z: <https://www.mathworks.com/help/stats/kstest.html>

- [24] Vartestn. *MathWorks* [online]. [cit. 2020-04-10]. Dostupné z: <https://www.mathworks.com/help/stats/vartestn.html#d120e737989>
- [25] Ranksum. *MathWorks* [online]. [cit. 2020-04-10]. Dostupné z: <https://www.mathworks.com/help/stats/ranksum.html>
- [26] Kruskalwallis. *MathWorks* [online]. [cit. 2020-04-10]. Dostupné z: <https://www.mathworks.com/help/stats/kruskalwallis.html#d120e426338>
- [27] Multcompare. *MathWorks* [online]. [cit. 2020-04-10]. Dostupné z: <https://www.mathworks.com/help/stats/multcompare.html>
- [28] *Detekce polohy objektů pomocí zpracování obrazu*. Brno, 2016. Diplomová práce. Mendelova univerzita v Brně.

Seznam příloh

Příloha A: Výsledné binární modely.

Příloha B: Výstupy barevných map distribuce tloušťky aorty.


Přiložený ZIP soubor:

- Složka *kody_a_algoritmy* obsahující jednotlivé funkce v *m.souborech*, použité v této diplomové práci. Součástí jsou hlavičky kódů vysvětlující jednotlivé proměnné v *m.souborech*.
- Složka *Video_soubory* obsahuje data použítá k analýze a dále složky pro všech sedm videozáznamů. Složky obsahují veškeré výstupy provedených analýz.

Příloha A



Obr. 73: Binární model Videá 1.




Obr. 74: Binární model Videá 2.



Obr. 75: Binární model Videá 3.



Obr. 76: Binární model Videá 4.



Obr. 77: Binární model Videá 5.




Obr. 78: Binární model Videá 6.




Obr. 79: Binární model Videá 7.


Příloha B




Obr. 80: Barevné mapování distribuce tloušťky aorty pro Video 1.




Obr. 81: Barevné mapování distribuce tloušťky aorty pro Video 2.




Obr. 82: Barevné mapování distribuce tloušťky aorty pro Video 3.




Obr. 83: Barevné mapování distribuce tloušťky aorty pro Video 4.



Obr. 84: Barevné mapování distribuce tloušťky aorty pro Video 5.



Obr. 85: Barevné mapování distribuce tloušťky aorty pro Video 6.



Obr. 86: Barevné mapování distribuce tloušťky aorty pro Video 7.